

Санкт-Петербургский государственный университет

ВАСИЛЬЕВ Николай Дмитриевич

Выпускная квалификационная работа

Разработка алгоритмического обеспечения для задач спутникового мониторинга растительности на примере выявления лесных рубок и картографирования плантаций каучука

Уровень образования: бакалавриат

Направление: 05.03.03 «Картография и геоинформатика»

Основная образовательная программа: СВ.5020. «Картография и геоинформатика»

Профиль: «Геоинформатика»

Научный руководитель:

доц. кафедры картографии и геоинформатики,

Институт Наук о Земле,

к.г.н., доц. Капралов Евгений Геннадьевич

Рецензент:

проф. кафедры картографии,

Военно-космическая академия им. А.Ф. Можайского,

д.г.н., проф. Осипов Георгий Константинович

Санкт-Петербург

2019

Содержание

Введение.....	3
Глава 1 Роль дистанционного зондирования Земли в системах мониторинга.....	5
1.1 Дистанционное зондирование Земли: преимущества и недостатки.....	5
1.2 Проблемы, возникающие в дистанционном зондировании Земли.....	6
1.3 Использование дистанционного зондирования Земли для мониторинга и выявления вырубок.....	10
1.4 Использование дистанционного зондирования Земли для мониторинга и картографирования плантаций каучуковых деревьев.....	11
Глава 2 Алгоритм мониторинга вырубок и картографирования плантаций каучуковых деревьев.....	13
2.1 Постановка задачи.....	13
2.2 Математический аппарат.....	15
2.2.1 Битовые операции.....	15
2.2.2 Метод наименьших квадратов.....	16
2.2.3 Элементы теории вероятности.....	17
2.2.4 Нейронные сети.....	17
2.2.5 Метод скользящего окна.....	20
2.2.6 Гармонические модели.....	20
2.3 Исходные данные и изучаемая территория.....	21
2.4 Программное обеспечение, необходимое для работы.....	24
2.5 Общая концепция алгоритма.....	25
2.6 Предварительная обработка данных.....	27
2.6.1 Радиометрическая калибровка.....	27
2.6.2 Атмосферная коррекция.....	28
2.6.3 Топографическая коррекция.....	31
2.6.4 Выявление облаков и теней от облаков и снежного покрова.....	34
2.6.5 Фильтрация.....	36
2.7 Формирование временных срезов и построение гармонической модели.....	38
2.8 Создание и обучение нейронной сети.....	40
2.9 Предсказание меток классов.....	44
Глава 3 Использование алгоритма для выделения рубок и плантаций каучуковых деревьев.....	46
3.1 Особенности использования алгоритма для выделения рубок.....	46

3.2 Особенности использования алгоритма для выделения плантаций	
каучуковых деревьев.....	49
Заключение.....	54
Список литературы.....	55

Введение

Сокращение площади лесов – одна из острых проблем, которая стоит перед человеком. Причинами обезлесения являются не только стихийные бедствия, такие как пожары и засуха, но и сам человек. В последние десятилетия увеличилось количество незаконных рубок во многих регионах мира, в том числе и в РФ. На территории Дальнего Востока лесные массивы занимают до 30% площади всех лесов страны. В этом районе обитают десятки видов животных и растений, которые занесены в Красную книгу. Разрушение естественной среды обитания окажет на них существенное негативное влияние. Огромная по площади территория, богатая ценными породами древесины всегда привлекала браконьеров как источник дешевого материала. Контролирование территории и пресечение незаконной деятельности очень тяжело достичь, используя только традиционные «наземные» методы. Поэтому разработка алгоритмов мониторинга вырубок с использованием данных дистанционного зондирования является актуальной задачей.

В Юго-Восточной Азии активно развивалось и развивается выращивание каучуковых деревьев, что связано с историческими особенностями развития данного региона. Как правило, новые плантации возникают на месте вырубленных тропических лесов или земель, выведенных из-под сельскохозяйственного оборота. Смола каучука является сырьем для производства резины, различного рода уплотнителей для термо-, гидро- и звукоизоляции, твердого топлива ракет и др., а древесину дерева используют в мебельной промышленности. Помимо этого, распространение каучуковых деревьев интересно специалистам разных биологических направлений. Поэтому мониторинг плантаций каучука так важен, и для него сегодня используются космические снимки.

На сегодняшний день разработан ряд методов для решения как первого, так и второго вопросов, о чем будет сказано ниже. Однако все они имеют свои недостатки, что ограничивает их применение. Целью данной работы является разработка альтернативного алгоритма, который мог бы использоваться в системе мониторинга как рубок, так и плантаций каучука. Такой подход, с одной стороны, обладает большей универсальностью, а с другой – учитывает слабые стороны существующих методик.

Для достижения поставленной цели было необходимо решить следующие задачи:

- изучить разработанные алгоритмы, применяющие данные дистанционного зондирования в системах мониторинга, ограничения методик и возможные пути их разрешения;
- изучить программные средства, которые могут быть применены для решения задач, возникающих на различных этапах алгоритма;
- рассмотреть вопросы применимости данных дистанционного зондирования Земли в качестве исходных материалов алгоритма;

- применить методы машинного обучения для нахождения рубок и плантаций каучуковых деревьев;
- произвести оценку качества используемой модели и ее применимости на новых данных;

Разработка представленного в этой работе алгоритма была выполнена совместно с Колесовым Д.А. и другими сотрудниками компании ООО "NextGIS". Векторные данные по рубкам на Дальнем Востоке РФ и плантациям каучуковых деревьев в Юго-Восточной Азии были предоставлены ООО "NextGIS".

Глава 1 Роль дистанционного зондирования Земли в системах мониторинга

1.1 Дистанционное зондирование Земли: преимущества и недостатки

Дистанционное зондирование (ДЗ¹) – бесконтактный способ получения информации об изучаемом объекте или явлении. На сегодняшний день он становится одним из ведущих, что обусловлено его отличительными особенностями в сравнении с другими методами. ДЗ позволяет:

- получать информацию о труднодоступных объектах (изучение морского дна с использованием SONAR² съемки);
- изучать объекты, находящиеся вне зоны досягаемости человека (поверхности других планет, исследование звездных систем и др.);
- быстро получать информацию на большие территории (космическая съемка Земли);
- в короткий срок извлекать информацию с высокой плотностью и точностью (LIDAR³ съемка); под плотностью здесь понимается количество измерений, приходящиеся на единицу площади поверхности объекта (если речь идет о предметах) или в единице объема пространства (если речь идет о явлениях).

Благодаря этому становится возможным получать целостную картину об исследуемом предмете, что, несомненно, невозможно другими методами.

Однако информацию об объекте с применением методов ДЗ можно получить только через его дискретизацию⁴. Так, в отношении к космической съемке применяют следующие характеристики точности и полноты получаемых данных:

- пространственное разрешение: минимальный размер объекта, который еще может быть различен сенсорами. Как правило, на это влияет конструкция зондирующей системы, расстояние до исследуемого объекта и такое явление, как дифракция, которое проявляется в том, что бесконечно удаленная точка не изображается точкой на снимке, что видно из Рис.1.
- спектральное разрешение: способность сенсоров различать сигналы, относящиеся к разным участкам электромагнитного спектра;

¹ Здесь и далее приняты сокращения: ДЗ – дистанционное зондирование, ДЗЗ – дистанционное зондирование Земли, ДДЗ – данные дистанционного зондирования.

² SONAR (Sound navigation and ranging) – гидроакустическая станция или ультразвуковой локаатор.

³ LIDAR (Light Identification Detection and Ranging) – обнаружение, идентификация и определение дальности с помощью света.

⁴ Имеется в виду, насколько будет полной информация о конкретном объекте.

- временное разрешение: время между двумя последовательными съемками одной и той же территории. Эта величина варьируется от одного дня (MODIS) до 5¹ (Sentinel-2) и 16 дней (Landsat-7,8);
- радиометрическое разрешение: величина, показывающая, насколько чувствителен сенсор по отношению к регистрируемым сигналам.

1.2 Проблемы, возникающие в дистанционном зондировании Земли

Какой бы метод дистанционного зондирования не использовался, любая информация получается через сигналы, в роли которых выступают волны (звуковые, электромагнитные, упругие и др.). Поэтому качество получаемой информации зависит от их чистоты, то есть от того, насколько они свободны от шума. При космической съемке земной поверхности сигнал проходит через атмосферу, которая не является прозрачной для них. Поэтому в этом случае она оказывает огромное влияние на окончательный результат и должна учитываться при расчетах.

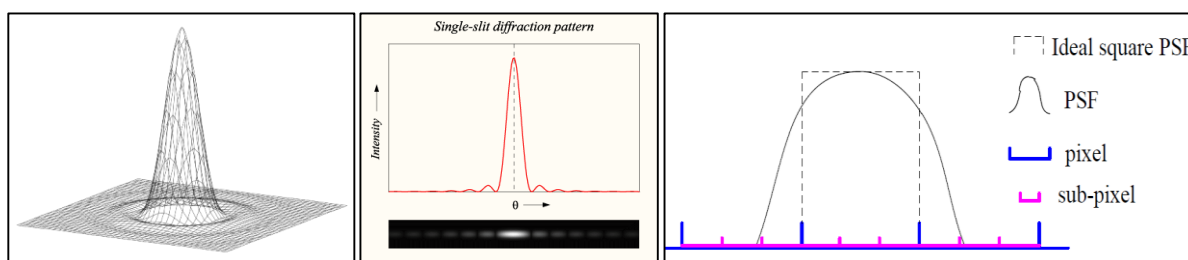


Рис.1. Интенсивность сигнала, полученного с далекой точки. Слева – общий вид PSF; центр – график PSF на плоскости; справа – график PSF для одного пикселя. Источник: <https://www.wavemetrics.com>

Далеко не всегда можно считать земную поверхность плоской. Поэтому необходимо вносить поправки за рельеф. Помимо этого, исследуемый объект может быть расположен за препятствием (например, почвенный покров под пологом леса) или иметь высокую отражательную способность (снежный покров, водные поверхности), что может приводить к многократному отражению одного и того же луча (эффект зеркала). Последнее является следствием таких артефактов, как появление точек, расположенных под землей (Рис.2).

Если недавно данные одиночных снимков удовлетворяли запросам практики, то теперь для анализа используется, как правило, серия снимков или временной ряд. Такой подход позволяет узнать больше информации. При этом возникает ряд трудностей, связанных с использованием снимков разного разрешения и покрывающих разные участки территории.

¹Здесь указан общий период съемки. Временное разрешение каждого из спутников Sentinel-2A и Sentinel-2B составляет 10 дней.

При анализе достаточно долгих рядов возникает необходимость в использовании снимков, полученных с давно запущенных спутников, таких как Landsat-7 (функционирует с апреля 1999 года), поскольку последний спутник – Landsat-8, начал работу только с февраля 2013 года. Однако в мае 2003 линейный корректор сканирования (scan line corrector, SLC) на Landsat-7 вышел из строя, в результате чего все его снимки имеют характерные «черные» полосы с пропущенными данными, покрывающие до 22% всей территории (Рис.8) (<https://www.usgs.gov/land-resources/nli/landsat>).

Для решения этой проблемы С.К. Максвелл и Г.Л. Шмидт предлагают использовать сегментацию изображения, выполненную в нескольких масштабах, на основе текстурного анализа при помощи алгоритма фрактальной эволюционной сети (fractal net evolution approach, FNEA). При этом предполагается наличие пространственной корреляции (каждый пиксель мало отличается от своих соседей), текстурной схожести (каждый пиксель похож на своих соседей в группе) и утверждается, что малые ландшафтные блоки не меняют своих границ на протяжении нескольких лет. Для заполнения пропусков используются снимки за период, максимально близкий к дате текущего снимка. Такой подход дает хорошие результаты, однако не способен выделить небольшие ландшафтные группы или линейные и протяженные объекты (Maxwell, Schmidt et al., 2007).

Геологическая служба США (US Geological Survey, USGS) и Национальное управление по аэронавтике и исследованию космического пространства (National Aeronautics and Space Administration, NASA) разработали свой алгоритм: построение локальных линейных гистограмм, который пересчитывает значения пикселей первого изображения в значения для второго. В скользящем окне, размер которого выбирается с запасом (должно быть хотя бы 2 непропущенных пикселя), строится линейная регрессия для всех «чистых» пикселей. По результатам решения системы уравнений получаются 2 параметра: коэффициент и смещение, используемые для пересчета. Наличие облаков или снега (теней) вызывают завышение (занижение) коэффициентов и ухудшают качество результата. Помимо этого, если на снимках произошли какие-либо значимые изменения, то малые объекты местности будут утеряны. Поэтому алгоритм хорошо работает только для однородных территорий (<https://landsat.usgs.gov/sites/default/files/documents/L7SLCgapFilledMethod.pdf>).

Подход, предложенный С.Чжаном и Д.Трэвисом, имеет те же ограничения и предположения, что и описанный выше метод гистограмм, однако отличается тем, что не предполагает привлечения дополнительных снимков: заполнение пропусков идет только на основе информации о соседях при помощи геостатистических методов - кригинга и построения семивариограмм. Эти модели представляют из себя разновидность метода наименьших квадратов, но учитывают пространственные связи. При этом решение

гарантирует минимальную ошибку дисперсии. Как показали авторы, исходные данные должны иметь нормальное распределение; в противном случае, их необходимо трансформировать. Этот метод показывает высокую точность, однако не способен выделить небольшие объекты из-за нехватки данных об их соседях. Кроме того, данный метод требует значительных вычислительных ресурсов (Zhang, Li et al., 2007).

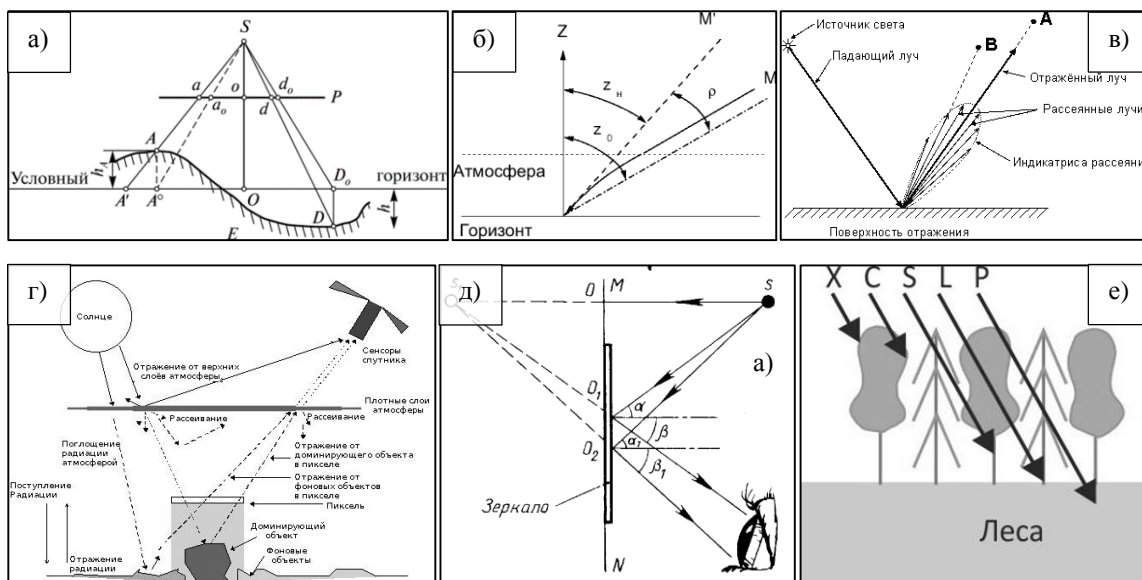


Рис.2. Влияние атмосферы и подстилающей поверхности: а) рельефа; б) атмосферной рефракции; в) рассеяния объектом; г) рассеяния атмосферой; д) эффекта зеркала; е) проникающей способности. Источник:

<https://mykonspekts.ru>

Наконец, алгоритм, предложенный Д.Ченом, К.Чжу, Дж.Фогельманом и др., представляет из себя компромисс описанных выше подходов. Здесь также, как и в (<https://landsat.usgs.gov/sites/default/files/documents/L7SLCGapFilledMethod.pdf>) используется несколько изображений и скользящее окно, размер которого устанавливается в процессе оптимизации. Однако здесь в пределах скользящего окна выбираются только те пиксели, которые наиболее похожи на целевой пиксель. Подобно С.Чжану и др. значение пикселя вычисляется как взвешенная сумма похожих на него соседей (первое предсказание), но, с другой стороны, является функцией взвешенной суммы изменений, произошедших с похожими на него пикселями на основе известного изображения (второе предсказание). Так же, как и С.К. Максвелл и др., авторы используют прилежащие значения для предсказаний, но не ограничиваются при этом только одним соседом. Полученные результаты указывают на их зависимость от выбросов, однако данный метод является более устойчивым к большим интервалам времени между снимками и способен давать хорошие результаты на разнородные участки (Chen, Zhu et al., 2011).

Как правило, один спутник ведет съемку в нескольких каналах с разным пространственным разрешением. Поэтому становится возможным приведение каналов

низкого пространственного разрешения к более высокому на основании информации, хранящейся в каналах высокого разрешения; при этом сохраняется спектральное разрешение снимка, и в итоге получается изображение с высоким пространственным и спектральным разрешениями. Такая процедура называется слиянием (pan-sharpening, sharpening) и используется для возможности работы со снимками более высокого разрешения и для работы со снимками, полученными с разных спутниковых систем. Как показал Ю.Чжан, получение готовых снимков, которые имели бы высокое разрешение (как пространственное, так и спектральное) ограничено двумя факторами: приходящей на сенсор радиацией и объемом данных, которые сенсор способен принять (Zhang, 2004).

Д. Пушпарадж и А.Хедж сравнили 10 способов «улучшения» качества изображения при помощи слияния. При этом они оценивали результат при помощи объективных (14 статистических показателей) и субъективных оценок (экспертное мнение) (Pushparaj, Hegde, 2017). Более глубокие исследования методов оценивания результатов слияния рассмотрены в работах Ц.Ду, предложившего помимо упомянутых подходов еще и сравнение посредством классификации, выделения объектов и линейного разложения (Du, Younan et al., 2007), и Л.Фонсеки, всесторонне рассмотревшей существующие методики проведения оценок и продемонстрировавшей достоинства и недостатки нескольких техник слияния на примере классификации природных объектов, классификации объектов на урбанизированной территории и анализе оползневых процессов (<https://www.intechopen.com/books/image-fusion-and-its-applications/image-fusion-for-remote-sensing-applications>).

В практике использования ДДЗ часто возникает необходимость переходить от одного разрешения изображения к другому. Если его ухудшение не составляет труда, то обратный процесс не так однозначен. Многие из методов слияния требуют в качестве одного из этапов улучшить разрешение снимков. Причина неоднозначности кроется в так называемой точечной функции распределения (point spread function, PSF), суть которой иллюстрирует Рис.1. Два основных подхода разрешения этого вопроса: на субпиксельном и пиксельном уровнях, рассмотрены К.Вангом и П.Аткинсом с использованием нейронной сети Хопфилда (Hopfield neural network, HNN) (Wang, Atkinson, 2017).

Обратную зависимость имеют, как правило, также пространственное и временное разрешение для разных спутниковых систем. Благодаря близким орбитальным характеристикам MODIS и Landsat, был разработан алгоритм STARFM (spectral and temporal adaptive reflectance fusion model), основанный на расчете взвешенной (по спектральной, временной и пространственной схожести пикселей) суммы отражательной способности. Модель способна работать только для участков, не претерпевающих значимых изменений в период съемки, и для не слишком разнородных ландшафтов (Gao, Masek et al., 2006). Этот

подход был использован Ф.Ма и Ц.Ваном для получения серии снимков с высоким пространственным и временным разрешением, на основе которого рассчитывалась серия индексов для мониторинга заболоченных земель в одной из провинции Китая (<https://jivp-eurasipjournals.springeropen.com/articles/10.1186/s13640-018-0305-7>). Д.Рой, Д.Джу и др. использовали так называемый «семифизический» метод, основанный на двулучевой функции отражательной способности (bidirectional reflectance distribution function, BRDF) (Lucht, Schaaf et al., 2017) и предложили его для восстановления пропущенных данных Landsat-7 (Roy, Ju et al., 2008).

Другая часто используемая комбинация спутников – Landsat и Sentinel-2. В отличие от MODIS, разрешение Sentinel-2 не сильно отличается от Landsat¹, а его проекция совпадает с проекцией последнего. Ц.Ван, Дж.А.Блэкберн и др. предложили основанный на кригинге алгоритм – area to point regression kriging (ATPRK), в котором предполагалось существование функциональной связи между снимками, полученными разными сенсорами (OLI у Landsat-8 и MSI у Sentinel-2), в виде двух компонент – тренда (регрессионная модель) и остатка (кригинговая модель). Метод, в целом, показал хорошие результаты и может быть использован при анализе лесного покрова или развития урбанизированных территорий (Wang, Blackburn et al., 2017).

Решение вопросов, касающихся влияния атмосферы и подстилающей поверхности, рассмотрены в Главе 2.

1.3 Использование дистанционного зондирования Земли для мониторинга и выявления вырубок

ДЗЗ, несомненно, играет важную роль в лесном хозяйстве, поскольку: позволяют картографировать распространение растительного покрова, служат средством обнаружения пожаров, участвуют в системах мониторинга по определению состояния растительности и помогают решать задачи идентификации незаконных вырубок.

Одной из наиболее удачных попыток по разработке методик для системы мониторинга изменения растительного покрова в реальном времени является алгоритм CCDC (continuous change detection and classification), предложенный Ж.Чжу и К.Вудкоком для построения синусно-косинусной модели, отображающей как общий тренд, так и годовые и сезонные изменения с целью выделения различного рода произошедших на территории перемен (Zhu, Woodcock, 2014b). С.Танг, Э.Буллок и др. модифицировали этот алгоритм

¹ Разрешение Landsat, Sentinel-2 и MODIS в видимом диапазоне составляет 30, 15 и 500 м соответственно.

(NRT-CCDC), показав возможность его применения для мониторинга вырубок в тропических лесах на территории Бразилии и Колумбии с использованием снимков как MODIS, так и Landsat-7. В оценку своих методик авторы положили 2 основные позиции: способность выделять очень маленькие изменения и временной интервал, необходимый для обнаружения алгоритмом изменений (Tang, Bullock et al., 2019).

С.Питон, Г.Джубелин и др. применили статистический подход для идентификации вырубок в тропических лесах Французской Гвианы на основе сравнения схожести (KL divergence) фактического и теоретического (Гауссова функция) распределения значений пикселей, используя NDVI¹ и NDWI² по данным сенсора SPOT 5 (Pithon, Jubelin et al., 2012).

Для мониторинга обезлесения и картографирования лесов возможно применение не только спутников с пассивным режимом съемки, но и с активным, примером чего может служить радарная съемка. Используя ресурсы SAR (Synthetic Aperture Radar L-band) японского спутника (Japanese Earth Resource Satellite, JERS), С.Тиэль, П.Дрезет и др. на примере 5 различных участков с разными характеристиками показали возможность применения как одиночных, так и серии предварительно сегментированных снимков для классификации на несколько групп с целью выделения лесных массивов и вырубленных участков со средней точностью около 90%. При этом ведущими факторами, влияющими на аккуратность, оказались рельеф, климатические условия и наличие населенных пунктов (Thiel, Drezet et al., 2006). М.Мустафа, Г.Сингх установили зависимость между интерферометрической когерентностью немецкого радиолокационного спутника TanDEM-X (pol-InSAR) в канале X и обезлесением территории: исчезновение растительности приводит к повышению когерентности (Musthafa, Singh et al., 2018).

1.4 Использование дистанционного зондирования Земли для мониторинга и картографирования плантаций каучуковых деревьев

Космическая съемка может применяться и для мелко-, и среднемасштабного картографирования. Большой объем открытых данных открывает возможности их использования.

Особое место занимает картографирование плантаций каучука³ с помощью ДДЗ. В конце прошлого века в странах Юго-Восточной Азии – Таиланде, Южном Китае, Камбодже,

¹ NDVI (Normalized difference vegetation index) – нормализованный относительный индекс растительности.

² NDWI (Normalized difference water index) – нормализованный разностный индекс воды.

³ Здесь и далее под каучуком будут пониматься каучуковые деревья.

Вьетнаме, Лаосе наблюдалось резкое сокращение лесов и распространение переложного земледелия, а после - выращивание таких культур, как бамбук, каучук и др. (Fox, Vogler, 2005)

Как показывают многие исследования, автоматическое выделение на снимках плантаций каучука является достаточно сложной задачей, поскольку само листовое покрытие этого растения занимает не много места по сравнению с другими сельскохозяйственными культурами, его спектральные характеристики во многом совпадают с другими типами растительности того региона, где он произрастает (в основном с вечнозелеными или широколиственными лесами) и имеют высокий разброс значений, связанных как с фенологическими особенностями растения в течение жизненного цикла, так и с условиями местообитания. Наконец, каучук занимает сравнительно небольшую площадь в том отношении, что его доля во всей плантации может сильно варьироваться, что вызвано частым смешиванием с другими растениями (Li, Fox, 2010).

Не все методы машинного обучения способны правильно выделить плантации каучука, явно переоценивая занимаемую ими площадь. На основе синтетических данных, представляющих из себя NDVI, полученный с MODIS, национальную и региональную статистику в качестве справочного материала, Ж.Ли и Дж.Фокс использовали один из методов «мягкого» обучения (модель Махаланобиса) для нахождения плантаций в Юго-Восточной Азии с точностью до 95% (Li, Fox, 2012). Они смогли достичь небольшого улучшения по сравнению с другими методами «жесткого» обучения, применив комбинированную модель, в которой вычисляемая вначале серия изображений по алгоритму Махаланобиса вместе с NDVI и снимками, полученными с ASTER, подаются на вход нейронной сети типа многослойного персептрона (multilayer perceptron, MLP) (Li, Fox, 2010). Однако это точность в целом хуже, чем у (Li, Fox, 2012).

Другие исследования были проведены по картографированию сокращения лесов и распространения плантаций с использованием серии снимков Landsat Д.Таном, Х.Фаном и др. на границе Лаоса и Китая (Tang, Fan et al., 2019) и К.Гроганом, Д.Пфлугмахером и др. на границе Камбоджи и Вьетнама (Grogan, Pflugmacher et al., 2015).

Таким образом, методы ДЗЗ могут использоваться для решения задач мониторинга рубок и плантаций каучука. При этом необходимо учитывать многие факторы: влияние внешней среды, разные спутниковые системы и др., чтобы получить корректные результаты. Ниже представлен альтернативный алгоритм для выделения рубок и плантаций.

Глава 2 Алгоритм мониторинга вырубок и картографирования плантаций каучуковых деревьев

2.1 Постановка задачи

Картографирование каучука имеет важное значение. Во-первых, как показали исследования по картографированию динамики лесов в странах Юго-Восточного азиатского региона, площадь лесных массивов резко сократилась в конце XX века и в период с 2000 по 2016 годов, что связано с развитием переложного земледелия, при котором земля используется до тех пор, пока она плодородна. Социальная и экономическая политика, проводимая этими странами на тот период, а также особенности развития рынков товарных культур способствовали резкому распространению плантаций бамбука, каучука и др. (Tang, Fan et al., 2019; Grogan, Pflugmacher et al., 2015)

Во-вторых, как правило, плантации каучука или фруктовые сады отличаются большим видовым разнообразием и содержанием биомассы, нежели рисовые поля или плантации эвкалипта, что вызвано наличием большого количества «сорняков» (посторонних растений) из-за сложности ведения хозяйства. Из-за редкого покрова в первые годы после посадки почвы на каучуковых полях подвержены сильной эрозии (Shrestha, Schmidt-Vogt et al., 2010).

В-третьих, плантации каучука оказывают влияние на углеродный цикл той местности, где они произрастают. В общем случае, плотность насаждения этих растений существенно больше, чем у тех, что произрастают на землях, отведенных под подсечное земледелие, чего не скажешь о корневой системе. Влияние их на плодородие и эрозию почв оказывается приблизительно одинаковым в среднем. В целом, для каучука эти показатели остаются практически неизменными, в то время как при ведении переложного земледелия они сильно варьируются в зависимости от стадии цикла и способны достигать высоких значений только спустя 20-30 лет после обновления. Это является одной из причин, по которой сейчас такие земли стараются больше отводить под постоянное пользование, то есть отойти от практики ведения переложного земледелия (Fox, Castella et al., 2014).

Исходя из этих фактов, картографирование плантаций каучука позволяет принимать меры против эрозии почв в соответствующих районах, косвенно получать информацию, важную для специалистов биологических направлений и может активно использоваться в сельском хозяйстве.

Мониторинг рубок также представляет из себя одну из важных задач. На территории РФ действуют следующие основные нормативно-правовые акты, регулирующие деятельность и контроль, связанные с незаконными рубками:

- "Уголовный кодекс Российской Федерации" от 13.06.1996 N 63-ФЗ (ст. 260 «Незаконная рубка лесных насаждений»);
- «Лесной кодекс Российской Федерации» от 01.01.2019 (ст. 16 «Рубки лесных насаждений»; ст. 99 «Административная, уголовная ответственность за нарушение лесного законодательства»);
- «Кодекс Российской Федерации об административных правонарушениях» от 26.12.2001 (ст. 8.28 «Незаконная рубка, повреждение лесных насаждений или самовольное выкапывание в лесах деревьев, кустарников, лиан»);
- иные нормативно-правовые документы.



Рис.3. Символ WWF.
Источник:
<https://wwf.ru/>

Несмотря на это, на Дальнем Востоке и в других регионах остро стоит проблема незаконных рубок. По данным Лесной программы Всемирного фонда дикой природы (World Wildlife Fund, WWF) России (Рис.3) было установлено, что причиной этого являются: несовершенная система контроля, низкий уровень правоохранительных органов и отсутствие должного внимания на границе Россия-Китай за деятельностью «черных» лесорубов. Многократное увеличение допустимо установленного объема рубок на специально отведенных территориях приводит к деградации лесных экосистем и сокращению популяции редких видов животных, росту браконьерства в районах, в которых запрещено ведение какой-либо хозяйственной деятельности человека (заказники, заповедники и т.д.), ухудшению качества жизни местного населения (Незаконные рубки..., 2013).

Для наблюдений за обширными лесными пространствами намного эффективнее использовать материалы ДЗЗ. На текущий момент в РФ существует система мониторинга для ряда субъектов с использованием ДДЗ с высоким пространственным разрешением и данных, полученных от департаментов лесного хозяйства по федеральным округам, которая дает до 90% точности (https://sovzond.ru/upload/iblock/b75/7shimov_tekhnologia_monitoringa_virybok_lesa.pdf). Однако практически весь процесс основан на ручном подходе, что является его существенным недостатком.

В период 2007-2013 гг. был осуществлен мониторинг четырех лесничеств Амурской области с использованием снимков с высоким пространственным разрешением (до 0.5 м). Подобные снимки являются платными, поэтому использование их в режиме, близкому к реальному времени, составляет трудности и не дает использовать весь потенциал космических снимков (http://pnu.edu.ru/media/ejournal/articles-2014/TGU_4_336.pdf).

С 2015 года в РФ была введена система мониторинга изменений лесного покрова «КЕДР», использующая снимки открытого доступа среднего разрешения и постоянно обновляющая их в реальном времени. При этом любой человек может отметить информацию по нелегальным рубкам в специальном приложении, передавая тем самым эти данные в центр управления. Такой подход предоставляет больше преимуществ в сравнении с другими методами, что особенно важно для оперативного реагирования (<https://wwf.ru/resources/news/lesa/na-dalнем-vostoke-rossii-vnedryaetsya-unikalnaya-sistema-kedr>). Как было заявлено, такая модель способна определять любые изменения, малые и крупные (свыше 0.45 га) рубки с точностью 79%, 52% и 100% соответственно. Однако неизвестно, каким образом высчитывалась оценка точности, и что выступало в качестве критерия.

Обе описанные проблемы: картографирование плантаций каучука и обнаружение вырубок, не являются полностью решенными, поскольку:

- не всегда проводят предварительную обработку снимков, что может являться существенным в условиях пересеченного рельефа и непрозрачной атмосферы;
- не везде реализован подход, использующий серию снимков, что могло бы дать преимущества перед рассмотрением одиночных изображений;
- не все алгоритмы используют серии снимков, полученных с разных сенсоров, что увеличивает временное разрешение и повышает количество безоблачных измерений;
- ручной и полуавтоматический с сильным преобладанием ручной составляющей подходы не позволяют достичь приближенного к реальному времени режима наблюдения за состоянием растительного покрова.

Далее предлагается альтернативный алгоритм для решения этих задач.

2.2 Математический аппарат

Здесь приведены основные элементы, необходимые для понимания работы алгоритма. При этом битовые операции и метод скользящего окна используются в процессах предобработки; метод наименьших квадратов служит основой для построения гармонических моделей; элементы теории вероятности дают ключ к принятию решения на последних стадиях алгоритма; описание нейронных сетей предоставляет возможность понять внутренний механизм производимого обучения.

2.2.1 Битовые операции

Битовым вектором называют набор (последовательность) двоичных разрядов, то есть битов. Битовые операции – все операции, производимые над битовыми векторами. Основными из них являются: побитовое «И» (умножение, &), побитовое «ИЛИ» (сложение, |), побитовое исключающее «ИЛИ» (XOR), побитовая инверсия (~) и др. В таблице 1 представлены результаты их выполнения для двух переменных.

Таблица 1

Основные побитовые операции

A	B	A & B	A B	A XOR B	~ A
0	0	0	0	0	1
0	1	0	1	1	1
1	0	0	1	1	0
1	1	1	1	0	0

2.2.2 Метод наименьших квадратов

Метод наименьших квадратов (МНК) является одним из самых распространенных способов решения переопределенной системы линейных уравнений, то есть таких систем, в которых количество уравнений превышает число неизвестных:

$$\mathbf{A} * \mathbf{x} = \mathbf{y} \quad (1)$$

где \mathbf{A} – матрица коэффициентов, \mathbf{x} – вектор неизвестных, \mathbf{y} – вектор свободных членов. К уравнениям вида (1) сводится большинство задач, например, аппроксимация неизвестных функций под условием минимума суммы квадратов ошибок отклонений:

$$\hat{\mathbf{x}} = \operatorname{argmin}_{\mathbf{x}} \sum \varepsilon_i^2 \quad (2)$$

где $\hat{\mathbf{x}}$ – набор оптимальных параметров, ε_i – отклонение модели в точке i . В общем случае решение системы (1) при наличии условия (2) будет выглядеть:

$$\mathbf{x} = \mathbf{A}^+ * \mathbf{y} \quad (3)$$

Здесь \mathbf{A}^+ – псевдообратная матрица, определяемая:

$$\mathbf{A}^+ = (\mathbf{A}^T * \mathbf{A})^{-1} * \mathbf{A}^T \quad (4)$$

Знак T означает транспонирование. Решение, даваемое (3), оптимально в том смысле, что оно позволяет построить максимально близкую к реальным данным функцию из всего ее семейства.

Очень часто требуется наложить некоторые ограничения на параметры, чтобы они не были слишком большими или, наоборот, слишком маленькими. Такой процесс называют регуляризацией. В таком случае уравнение (2) видоизменяется следующим образом:

$$\hat{\mathbf{x}} = \operatorname{argmin}_{\mathbf{x}} \sum w_i \varepsilon_i^2 \quad (5)$$

где w_i – вес ошибки в точке i , отражающий ее вклад в общую сумму. Такой подход использует модифицированный МНК – устойчивая регрессия (robust regression). Дальнейшие подробности МНК отображены в (Elementary Linear Algebra, 2004).

2.2.3 Элементы теории вероятности

Теория вероятности – основной инструмент методов машинного обучения. Вероятность понимают в двух смыслах: частота повторяемости некоторого события и степень уверенности в том, что некоторое событие произойдет (Байесовский подход). Основные требования к вероятности следующие:

$$1 \geq P(\mathbf{A}) \geq 0, \mathbf{A} - \text{событие} \quad (6)$$

$$P(\emptyset) = 0, \text{ где } \emptyset - \text{невозможное событие} \quad (7)$$

$$P(\mathbf{U}) = 1, \text{ где } \mathbf{U} - \text{достоверное событие} \quad (8)$$

Очень часто рассматриваемые события не являются независимыми; в этом случае используют такое понятие, как условная вероятность. Например, далее потребуется определить вероятность того, что наблюдаемый набор параметров \mathbf{D} относится к классу \mathbf{c} : $P(y=\mathbf{c}|\mathbf{D})$.

Если существует переменная, которая может принимать случайным образом набор значений, то на ее основе можно построить случайную величину. Для любой такой величины \mathbf{X} определена функция $p(\mathbf{X}=\mathbf{x})$, где p – функция плотности. В задачах машинного обучения часто возникает необходимость нахождения моды или медианы подобной кривой. Так в случае классификации объекта нужно было определить, относится он к вырубке или нет. В этом случае можно применить метод максимальной апостериорной оценки (maximum a posteriori estimation, MAP), суть которого выражается уравнением:

$$\hat{\theta}_{MAP} = \operatorname{argmax}_{\theta} p(y|\mathbf{X}) \quad (9)$$

который в общем случае просто отыскивает моду распределения $p(y|\mathbf{X})$. Такой подход отличается от другого известного случая – метода максимального правдоподобия (maximum likelihood estimation, MLE), суть которого в максимизации функции $p(\mathbf{X}|y)$, что часто используется в Байесовских моделях. Более детально с теорией вероятности можно ознакомиться в (Sahoo, 2013).

2.2.4 Нейронные сети

Концепция нейронных сетей не является на сегодняшний день чем-то новым, поскольку сам подход и многие варианты его реализации были разработаны еще в прошлом веке. Их активное использование сейчас связано с развитием вычислительной техники и открытыми данными. Существует огромное количество различных архитектур сетей: многослойные перцептроны, сверточные и рекуррентные сети, сети Хопфилда и цепи Маркова, сети радиально-базисных функций и машина Больцмана и др. (Deep Learning, 2016) Из перечисленных моделей в работе использовалась только одна, описанная ниже.

Многослойные перцептроны (MLP) представляют из себя совокупность объединенных нейронов. При этом выделяют входной слой, выходной слой и один или несколько скрытых слоев (Рис.4а). Сами нейроны представляют из себя целостные единицы и на математическом уровне выглядят так, как показано на Рис.4б.

Сначала нейрон использует «сумматор», задача которого сложить входные сигналы. В простейшем случае для этого находится среднее взвешенное:

$$\Sigma = \mathbf{w} * \mathbf{x} \quad (10)$$

где \mathbf{w} – вектор весов, \mathbf{x} – вектор входных сигналов. После этого к получившемуся значению применяется функция активации, чтобы выходной сигнал был заключен в один из стандартных интервалов, например, $[0;1]$ или $[-1;1]$:

$$o = \varphi(\Sigma) \quad (11)$$

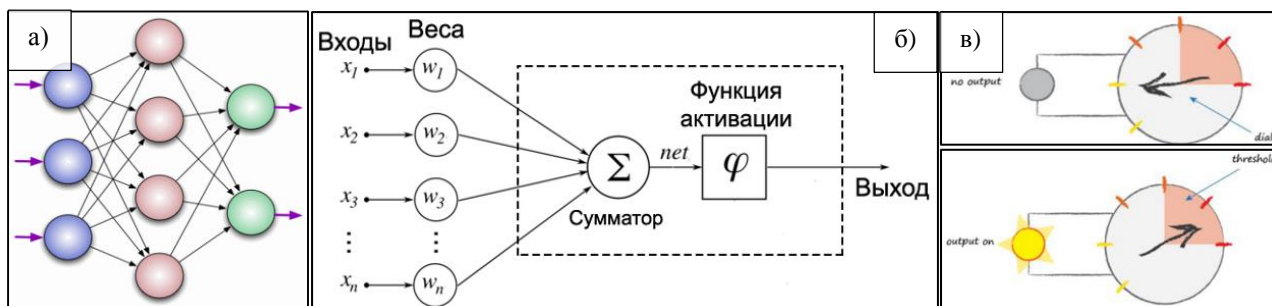


Рис.4. Нейронная сеть: а) общая структура сети; б) схема нейрона; в) работа активирующей функции.

Источник: (Rashid, 2016)

Как правило, если значение оказывается малым, то функция активации производит слабый сигнал, и нейрон «затухает» (Рис.4в). Подобные процессы происходят и в нервной системе живого существа, что позволяет ему получать информацию об окружающем мире. На Рис.5 приведены основные функции, широко использующиеся для активации.

При построении сетей обычно делают их полно связными: каждый нейрон текущего слоя соединен с каждым из последующего (Рис.4а). Необходимости в формировании связей вручную нет, поскольку алгоритм при обучении сам выберет необходимые значения для весов этих связей. Если для какой-то из них получится значение, близкое к 0, то это будет означать,

что два нейрона, между которыми она проходит, никак не связаны между собой. Начальная инициализация весов происходит автоматически.

Обучение сети основано на подходе обратного распространения (back propagation). Его суть заключается в том, что, когда алгоритм предсказывает значения для известных данных, то его ответ в общем не совпадет с правильным результатом. Ошибка, которую можно в этом случае посчитать как квадрат разности этих двух величин, используется для корректировки весов. При этом поправки получаются пропорционально весам и распространяются последовательно, начиная с последних нейронов и, далее, в направлении к входному слою.

Для исправления весов используется подход градиентного спуска, который на каждой итерации находит вектор наискорейшего убывания функции ошибки E и уменьшает ее в направлении, обратном градиенту, с заданным шагом α , то есть:

$$\Delta w_{i,j} = -\alpha \frac{\partial E}{\partial w_{i,j}} \quad (12)$$

Решая полученную систему, можно получить следующий ответ:

$$\Delta w_{i,j} = \alpha * E_j * \text{sigm}(\mathbf{O}_j) * (1 - \text{sigm}(\mathbf{O}_j)) * \mathbf{O}_i^T \quad (13)$$

где $\Delta w_{i,j}$ – поправка к весу между нейроном i одного слоя и нейроном j последующего слоя, E_j – ошибка, посчитанная для нейрона j , \mathbf{O}_j – вектор ответов для слоя, в котором находится нейрон j , \mathbf{O}_i – вектор ответов для слоя, в котором находится нейрон i , $\text{sigm}(x)$ – сигмоида, определяемая уравнением:

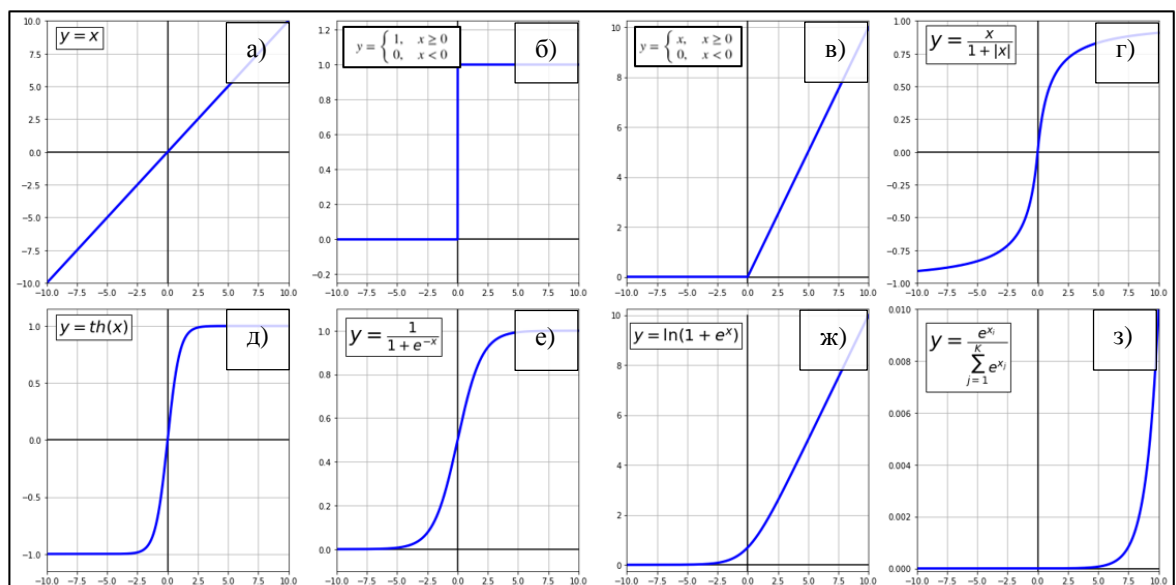


Рис.5. Примеры активирующих функции: а) тождественная; б) ступенчатая; в) ReLU^1 ; г) мягко знаковая²; д) гиперболический тангенс, е) сигмоида, ж) обратная сигмоида, з) сглаживающая

¹ RELU (rectified linear unit) – выпрямитель, определяемый как положительная часть аргумента.

² Авторский перевод; оригинальное название – softplus function.

$$\text{sigm}(x) = \frac{1}{1+e^x} \quad (14)$$

Вместо нее может использоваться любая другая функция, приведенная на Рис.5. Дальнейшие подробности доступны в (Rashid, 2016).

2.2.5 Метод скользящего окна

Используется при фильтрации изображения. На каждой итерации рассматриваемый пиксель покрывается сеткой установленного размера того же разрешения, что и растр. Коэффициенты, содержащиеся в окне **w**, умножаются на соответственные пиксели **h** и суммируются:

$$\mathbf{h}' = \mathbf{w} * \mathbf{h} \quad (15)$$

где **h'** - итоговое значение. Рис.6 иллюстрирует принцип действия скользящего окна.




Рис.6. Принцип действия скользящего окна

Существуют фильтры для выделения границ, сглаживания или усиления контрастности и четкости, уменьшения и увеличения объектов на изображении. В дальнейшем понадобится только медианный фильтр, задача которого заключается в исключении выбросов, занимающих намного меньше места. Если говорить о сглаживании функции, то здесь окно выбирается так, чтобы захватить соседние точки, после чего находят медианное значение и заменяют им текущее в рассматриваемой точке (Рис.7).




Рис.7. Принцип действия медианного фильтра: синий – исходные данные; красный – данные, полученные после применения фильтра с размером окна 3; оранжевый – данные, полученные после применения фильтра с размером окна 5

2.2.6 Гармонические модели

Для представления тех или иных явлений могут быть полезны разные типы моделей. Например, события, протекающие по тому же принципу, что и радиоактивный распад, лучше всего аппроксимируются экспоненциальными функциями; явления, связанные с гравитационными или электромагнитными силами – степенными полиномами (не выше 3 степени); характер зависимости деформации от напряжения терпит разрыв в критической точке – здесь лучше подойдет кусочная функция.

При наблюдении за явлениями, обладающими свойством цикличности, нужно использовать периодические или гармонические модели, общий вид которых можно выразить уравнением:

$$y = c_0 + \sum_{i=1}^n (a_i * \cos(i * x) + b_i * \sin(i * x)) \quad (16)$$

где c_0, a_i, b_i – некоторые коэффициенты. При наложении большого количества «гармоник» (синусоид) становится возможным выделять не только общие периодические, но и внутренние изменения в пределах общих циклов. Применимость таких моделей оправдана еще и тем, что они способны аппроксимировать любую функцию. К недостаткам можно отнести медленную сходимость и чувствительность к выбросам.

2.3 Исходные данные и изучаемая территория

Алгоритм мониторинга рубок и картографирования плантаций каучука разрабатывался и тестировался для двух территорий. Первая из них расположена на Дальнем Востоке РФ и занимает Приморский край, Еврейскую Автономную область, южную часть Хабаровского края и Амурской области приблизительно между 43°00' с.ш. и 54°00' с.ш. по широте и от 127°40' в.д. до 141°10' в.д. по долготе (Рис.9а). Климат территории ярко выраженный сезонный: зима сухая и холодная со средней температурой января -14°C; лето влажное и теплое с температурой июля +20°C. Такие особенности связаны с влиянием муссонов, приносящих летом обильные осадки. Часто возникают туманы. На территории расположены 2 крупные горные цепи: Хингано-Буреинская со средними отметками 700-750 м и Сихоте-Алинь, высота которого в среднем достигает 800-1000 м, а отдельные вершины поднимаются выше 2 км. Средняя высота местности – 420 м над уровнем моря.

Вторая область расположена в Юго-Восточной Азии и занимает центральную и южную часть Таиланда и южную часть Мьянмы приблизительно от 6°20' с.ш. до 16°30' с.ш. в меридиональном направлении и от 97°40' в.д. до 101°20' в.д. в широтном (Рис.9б). Территория протянулась от тропической зоны на севере до экваториальной на юге. Климат

этой части делит год на три составляющие: жаркое и дождливое лето (май-октябрь), прохладную и сухую зиму (до февраля) и жаркий, но сухой переходный к лету сезон. Средняя температура в теплый период составляет $+30^{\circ}\text{C}$, холодного – до $+12^{\circ}\text{C}$. Здесь выпадает до 1600 (иногда и свыше 3500) мм осадков в год, что связано с влиянием муссона, дующего с северо-востока. Рельеф района неоднороден: южная, центральная и северо-восточная (плато Корат) части заняты низменностями с отметками около 150 м, тогда как в северной части расположены: возвышенность Фипаннам со средней отметкой 1100-1200 м на востоке и горная гряда Танентауджи с отметками 1500-2000 м на западе. Средняя отметка территории составляет 200 м.




Рис.8. Заполнение пропусков Landsat-7 с использованием близких по дате изображений по методу «Phase 2 Gap-Fill Algorithm Version 2.0», предложенного USGS: а) исходный снимок – Landsat-7 Path-110 Row-26 на 24.07.2012; б) снимок, используемый для заполнения первого - Landsat-7 Path-110 Row-26 на 26.08.2012; в) первый снимок, пропущенные значения которого были заполнены с использованием данных второго изображения. Все изображения даны в естественных цветах

В качестве исходных данных выступали космические снимки Landsat-7 и Landsat-8 на период с 01.01.2010 по 01.03.2019 для первой территории и с 01.01.2015 по 01.03.2019 – для второй. Вся работа была сделана в системе Google Earth Engine. В таблице 2 представлена вся информация по каналам этих спутников. Поскольку соответствующие каналы имеют близкий диапазон, то использование их в совместной обработке допустимо. Пропуски данных в снимках Landsat-7 были заполнены с использованием ближайших к ним по дате изображений

(рис.8). Используемые снимки на приведенные выше даты практически равномерно распределены в течение года (Рис.12а).

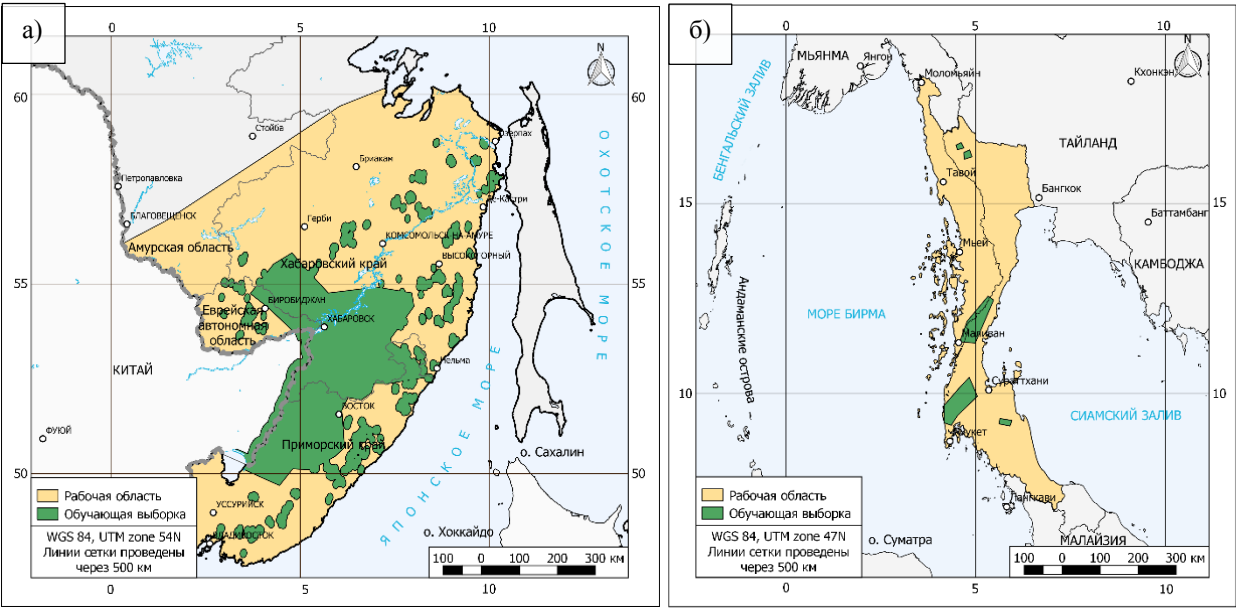


Рис.9. Тестовая территория: а) территория Дальнего Востока: масштаб 1:12 000 000, эллипсоид – WGS 84, проекция – UTM зона 54; б) территория Таиланда и прилежащих государств: масштаб 1:8 000 000, эллипсоид – WGS 84, проекция – UTM зона 47. Линии сетки проведены через 500 км. Оранжевый – рабочая область; зеленый – обучающая выборка

Таблица 2

Основные характеристики каналов Landsat-7, 8. Источник: URL: <https://www.usgs.gov/land-resources/nli/landsat>

Описание канала (диапазон)	Разрешение, м	Landsat-7		Landsat-8	
		№ канала	Длина волны (μ), мкм	№ канала	Длина волны (μ), мкм
темно-синий	30	—	—	B1	0.435-0.451
синий	30	B1	0.45-0.52	B2	0.452-0.512
зеленый	30	B2	0.52-0.60	B3	0.533-0.590
красный	30	B3	0.63-0.69	B4	0.636-0.673
ближний ИК	30	B4	0.77-0.90	B5	0.851-0.879
коротковолновый ИК 1	30	B5	1.55-1.75	B6	1.566-1.651
коротковолновый ИК 2	30	B7	2.08-2.35	B7	2.107-2.294
панхроматический	15	—	—	B8	0,500-0,680
дальний ИК (термальный 1)	100	B6	10.40-12.50	B10	10.60-11.19
дальний ИК (термальный 2)	100	—	—	B11	11.50-12.51
битовый	—	B9	—	B12	—

Несмотря на различия в местоположении, в климатических особенностях и других специфических чертах, эти территории имеют общие признаки: обе расположены в области муссонного климата, имеют ярко выраженные сухой и влажный сезоны, лежат в регионах с неоднородным рельефом и вытянуты в меридиональном направлении. Это позволяет объяснить применимость описанного далее алгоритма для обоих районов.

2.4 Программное обеспечение, необходимое для работы

Для разработки алгоритма был использован сервис Google Earth Engine (GEE), представляющий из себя платформу глобального масштаба для обработки ДЗЗ. Он предоставляет огромный инструментарий и позволяет писать программный код на языке JavaScript, а также пользоваться встроенными средствами, дающими возможность распределять вычислительную нагрузку между компьютером пользователя и серверами Google, что повышает производительность работы. Специальные контейнеры типов данных определяют, что будет обрабатываться на удаленных машинах (<https://earthengine.google.com>).

Одним из недостатков является ограничение на время ожидания ответа, составляющее, как правило, не более 5 минут. Хотя вычисления на удаленных серверах идут довольно быстро, этого бывает недостаточно для выполнения необходимых действий. В этом случае удастся обойти ограничение путем деления проблемы на подзадачи. Второй недостаток возникает в вопросах оптимизации алгоритмов. В отличие от ряда языков GEE¹ не имеет средств для решения вопросов, касающихся подбора наиболее оптимальных параметров. Поэтому алгоритм был переписан на язык Python, и настройка коэффициентов продолжалась на нем.

Python является высокоуровневым, интерпретируемым, многофункциональным языком с динамической типизацией, что предопределяет широту его распространения. Среди прочих он содержит библиотеку TensorFlow, всецело ориентированную на задачи машинного обучения (<https://www.tensorflow.org>). Она была использована для подбора оптимальных параметров алгоритма. Подбор коэффициентов производился методом сетки: выбирался диапазон возможных значений для каждого параметра, после чего программа, перебирая все возможные варианты их комбинаций, находила наилучшее сочетание в том смысле, что оно давало минимальную ошибку.

Несмотря на многофункциональность, Python достаточно медленный. Он позволяет писать удобочитаемые инструкции ценой лишения производительности. Поэтому для

¹ Имеется в виду JavaScript и специфические инструменты GEE.

обработки больших объемов географической информации использовалась геоинформационная система (ГИС) GRASS, все инструменты которой написаны на компилируемом языке низкого¹ уровня.

2.5 Общая концепция алгоритма

Общая схема работы алгоритма представлена на Рис.10 и включает в себя:

1. сбор исходных данных на необходимую территорию;
2. предобработку исходных данных, включающую в себя проведение радиометрической калибровки, атмосферной и топографической коррекций, выявление облаков, теней от облаков, а также фильтрацию снимков;
3. формирование временных срезов и построение гармонической модели для каждого канала;
4. создание нейронной сети;
5. обучение сети из п.4;
6. предсказание меток классов;
7. принятие решения.

Описание сбора данных для п.1 было дано выше. В дальнейшей работе использовались каналы: красный (red), зеленый (green), синий (blue), ближний ИК (nir), коротковолновый ИК 1 (swir1) и коротковолновый ИК 2 (swir2). Такой выбор обусловлен двумя причинами. Во-первых, использование других каналов затрудняет дальнейшую обработку, поскольку они отсутствуют у Landsat-7. Во-вторых, дальний ИК диапазон не дает ощутимо значимых результатов для рубок и растительности; темно-синий (фиолетовый) канал служит для определения содержания аэрозолей и может быть использован, например, в задачах поиска урбанизированных территорий.

Помимо представленных выше 6 каналов были посчитаны 3 индекса: NDVI, NDWI и NDSI²:

$$NDVI = \frac{nir - red}{nir + red} \quad (17)$$

$$NDWI = \frac{swir1 - nir}{swir1 + nir} \quad (18)$$

$$NDSI = \frac{swir1 - red}{swir1 + red} \quad (19)$$

¹ В основном все функции написаны на одном из языков семейства C, который не является низкоуровневым в строгом смысле этого слова. Но по сравнению с Python он не следит сам за распределением памяти машины в процессе выполнения программ и не предоставляет широкого набора готовых решений.

² NDSI (Normalized difference snow index) – нормализованный разностный индекс снежного покрова.

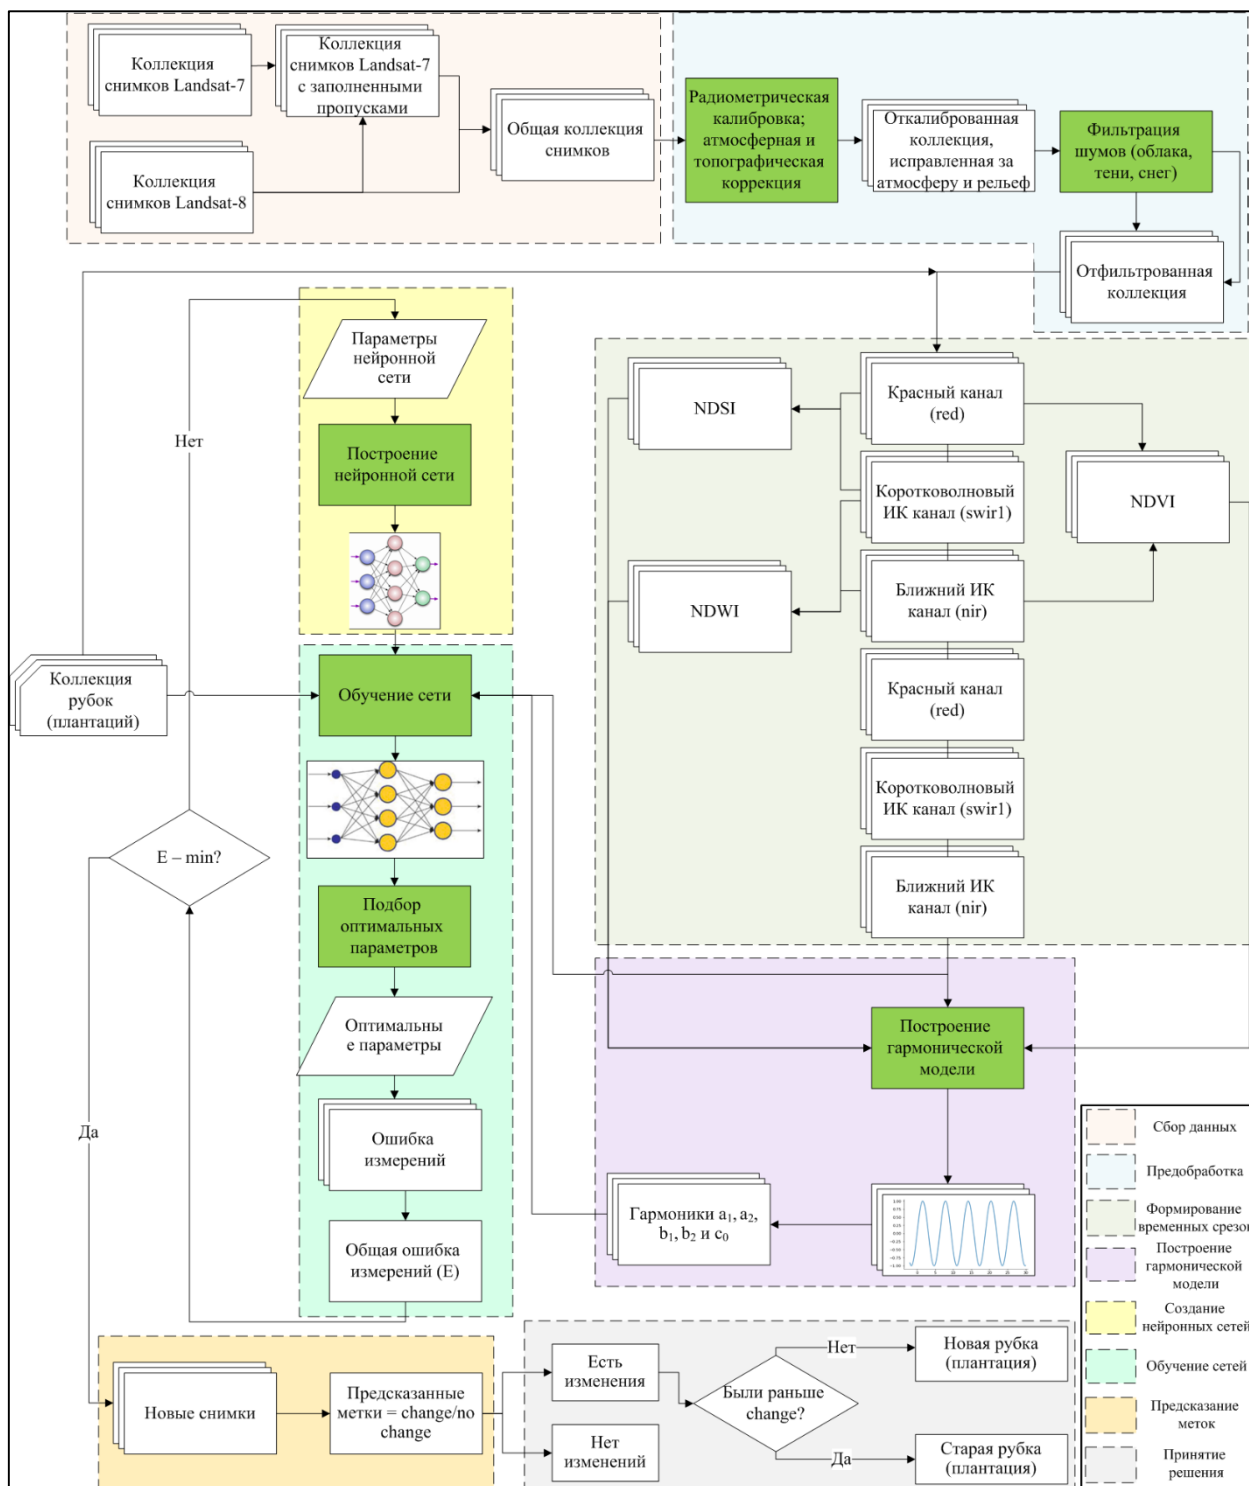


Рис.10. Схема алгоритма

Индекс (17) служит идентификатором растительного покрова, (18) необходим для поиска водных объектов и (19) позволяет находить снежный покров, который очень важен, поскольку служит основой для построения зимней нейронной сети (см. Главу 3).

П.2 необходим для максимального исключения шумов, которыми могут являться облачный покров, сильно завышающий значения, и тени, которые, наоборот, их занижают. Помимо этого, атмосфера не является абсолютно прозрачной средой для рабочего спектра и,

более того, далеко не статична. Поэтому ее влияние было учтено через атмосферную коррекцию. Как было сказано, рельеф изучаемых территорий не является плоским и имеет широкий разброс значений: от низменностей до высоких гор. Поэтому он также учитывался в анализе посредством топографической коррекции. Поскольку все эти методы не могут исключить шум целиком, который является источником сильных отклонений гармонических моделей, то применялся медианный фильтр для сглаживания наблюдений.

В п.3 формировались временные ряды для каждой вырубki (плантации) длительностью 6-7 лет, после чего на основе девяти показателей: шести каналов и трех индексов, строились гармонические модели для каждого из них для поиска неизвестных коэффициентов. Полученные таким образом данные подавались на вход нейронной сети для обучения (пп.4-5). После этого в п.6 сеть была использована на новых данных для предсказания неизвестных рубок (плантаций). Наконец, в п.7 определялся окончательный класс объекта на основе анализа состояния на предыдущие даты. Все шаги рассмотрены далее в деталях.

2.6 Предварительная обработка данных

2.6.1 Радиометрическая калибровка

Снимки, которые находятся в открытом доступе, имеют разный уровень обработки, в которую может входить радиометрическая калибровка, атмосферная коррекция и др. (<https://www.usgs.gov/land-resources/nli/landsat>) В этой работе использовались серии сырых снимков; все необходимые этапы предварительной обработки были сделаны самостоятельно, поскольку это дает возможность показать последовательность всех действий в общем случае и использовать произвольные методы.

Сырой снимок Landsat хранит в себе цифровые значения (digital numbers, DN), которые являются безразмерными величинами, пропорциональные интенсивности пришедшего на сенсор излучения в определенном волновом диапазоне. Также при определенных предположениях они оказываются приблизительно линейно связаны с отражательной способностью подстилающей поверхности и косинусом зенитного угла Солнца на момент съемки (Kowalik, Marsh, 1982). Эти безразмерные значения проходят трехступенчатую калибровку: предполетную (перед отправкой спутника на орбиту), во время работы спутника и послеполетную (специальные станции на Земле), что обеспечивает возможность их использования (Thome, Markharn et al., 1997).

Однако производить анализ снимков, сделанных на разные даты или на различные территории, становится возможным только после нормализации, то есть приведения

цифровых значений к физически единицам: излучению (Вт/м²) или отражательной способности атмосферы (top of atmosphere reflectance, TOAR, %). Для излучения:

$$L_{\lambda} = \frac{L_{max\lambda} - L_{min\lambda}}{Q_{max} - Q_{min}} * (Q_{cal} - Q_{min}) + L_{min\lambda} \quad (20)$$

где L_{λ} – пришедшее на сенсор излучение (Вт/м²), $L_{max\lambda}$ – максимальное излучение (Вт/м²), $L_{min\lambda}$ – минимальное излучение (Вт/м²), Q_{cal} – цифровое значение на снимке, Q_{max} – максимальное цифровое значение на снимке, Q_{min} – минимальное цифровое значение на снимке. После нахождения (20) можно найти TOAR следующим образом:

$$\rho_{\lambda} = \frac{\pi * L_{\lambda} * d^2}{ESUN_{\lambda} * \cos \theta_s} \quad (21)$$

где ρ_{λ} - TOAR, π – число пи (≈ 3.14), d – расстояние от Земли до Солнце на момент съемки (астрономические единицы, а.е.), $ESUN_{\lambda}$ – среднее солнечное излучение в атмосфере (Вт/м²), θ_s – зенитный угол Солнца (радианы, рад). При этом в отличие от излучения TOAR имеет ряд преимуществ: не зависит от направления излучения, компенсирует различия в солнечной радиации в разных каналах и учитывает расстояние до Солнце, которое меняется в течение года (Chander, Markham et al., 2009).

Файл с метаданными, идущим вместе со снимками, содержит, как правило, необходимые коэффициенты для непосредственного пересчета TOAR, минуя излучение. Практика показывает, что результат получается одним и тем же, независимо от способа расчета. В работе был использован последний подход, поскольку он является наименее затратным с вычислительной точки зрения. На Рис.13б представлено изображение, полученное после проведения радиометрической калибровки.

2.6.2 Атмосферная коррекция

Атмосфера не является прозрачной средой для сигнала, идущего от источника излучения до конкретного объекта на земной поверхности и обратно к сенсору. Сравнение 15-ти комбинаций различных техник атмосферной и топографической коррекций в целом указывают на повышение точности результатов анализа, что особенно актуально при работе с временными сериями (Vanonckelen, Lhermitte et al., 2013). Воздействие атмосферы, в основном, складывается из поглощения излучения газами (особенно озоном) и его рассеяния малыми взвешенными частицами – аэрозолями, широко распространенными как в тропосфере, так и в стратосфере. В верхних слоях воздушной среды эти частицы имеют в большинстве случаев стабильный и постоянный характер распространения, чего нельзя сказать о приземной толще (Fraser, Kaufman, 1985).

Существует множество алгоритмов, которые в той или иной степени учитывают влияние воздушной оболочки. К наиболее простым и ранним можно отнести методы из четырех основных групп: объектно-инвариантный подход, класс гистограммных соответствий, субтрактивная группа, основанная на поиске темных объектов, и серия способов контрастного уменьшения, в основе которых лежит анализ временных снимков. Позже появились более сложные алгоритмы, комбинирующие и использующие преимущества своих предшественников (Liang, Fang et al., 2001). Однако ни один из них не может в полной мере учесть все факторы, поскольку такие компоненты, как озон и кислород, являются относительно постоянными во времени и поддаются исчислению. Водяной пар может варьироваться в пространстве и времени, а данных для его учета не хватает. Наконец, аэрозоли представляют наибольшую трудность, поскольку эта составляющая является самой разнородной по составу, а их воздействие на проходящее излучение не до конца изучено, но установлено, что оно сопоставимо с влиянием облачного покрова (Kaufman, Tanré et al., 1997).

Для проведения атмосферной коррекции в этой работе использовался алгоритм 6S (Second Simulation of the Satellite Signal in the Solar Spectrum). Он является улучшенной версией более раннего метода 5S (Simulation of the Satellite Signal in the Solar Spectrum), но отличается от него большей точностью и возможностью учитывать дополнительные факторы. В отличие от других, 6S обладает рядом преимуществ: не рассматривает земную поверхность как ламбертову (что верно практически всегда), учитывает влияние таких газов, как метан, азот и угарный газ, и реализован на практике в виде простого и удобного инструмента (Vermote, Tanré et al., 1997).

В GEE и GRASS 6S алгоритм представлен с широким набором пользовательских настроек, которые позволяют выбрать сенсор, дату и время съемки, модели атмосферы и аэрозолей, дальность видимости (или оптическую плотность), среднюю высоту местности над уровнем моря, положение сенсора и канал, который требуется откорректировать (<http://gis-lab.info/qa/grass7-landsat8-processing.html>). В Таблице 3 приведено описание всех параметров. В таблице 4 представлены возможные значения каждой характеристики для обеих рабочих территорий.

Средняя высота местности может быть найдена по цифровой модели рельефа (ЦМР), положение сенсора имеет константное значение, поскольку работа велась исключительно с использованием спутниковых систем, модель атмосферы подбиралась с учетом климатических особенностей (лето или зима в средних широтах для первого участка и тропическая – для второго), в качестве модели для аэрозолей была выбрана морская (огромное влияние на оба участка оказывает океан). На Рис.14в представлено изображение, полученное после проведения атмосферной коррекции.

Таблица 3

Описание параметров алгоритма 6S. Источник: по данным сайта <http://gis-lab.info/qa/grass7-landsat8-processing.html>

Параметр	Вид записи	Расшифровка
Сенсор	N	номер (N) кода сенсора
Место, время и дата съемки	mm dd hh.dd lon lat	Месяц (mm), день (dd), час по Гринвичскому времени в десятичной записи (hh.dd), долгота (lon) и широта (lat) центра снимка
Модель атмосферы	N	номер (N) кода модели атмосферы
Модель аэрозолей	N	номер (N) кода модели аэрозолей
Оптическая плотность*	P	Значение (P) оптической плотности для выбранного канала на момент съемки
Средняя высота местности	H	Средняя высота местности (H) в км с обратным знаком
Положение сенсора	K/h	Номер кода (K), если сенсор расположен на борту спутника; если на борту воздушного судна, то высоту (h) полета
Канал	N	номер (N) кода используемого канала

Таблица 4

Возможные значения параметров для рабочих областей

Параметр	Дальний Восток	Юго-Восточная Азия
Сенсор	8 (ETM+, Landsat-7), 18 (OLI, Landsat-8)	
Место, время и дата съемки	05 27 13.47 135.61 50.00	07 01 14.12 99.20 9.47
Модель атмосферы	2 (лето в средних широтах), 3 (зима в средних широтах)	1 (тропическая)
Модель аэрозолей	2 (морская модель)	
Оптическая плотность*	67.321	101.473
Средняя высота местности	-0.78321	-0.41293
Положение сенсора	-1000 (на борту спутника)	
Канал	61-67 (каналы Landsat-7), 115-123 (каналы Landsat-8)	

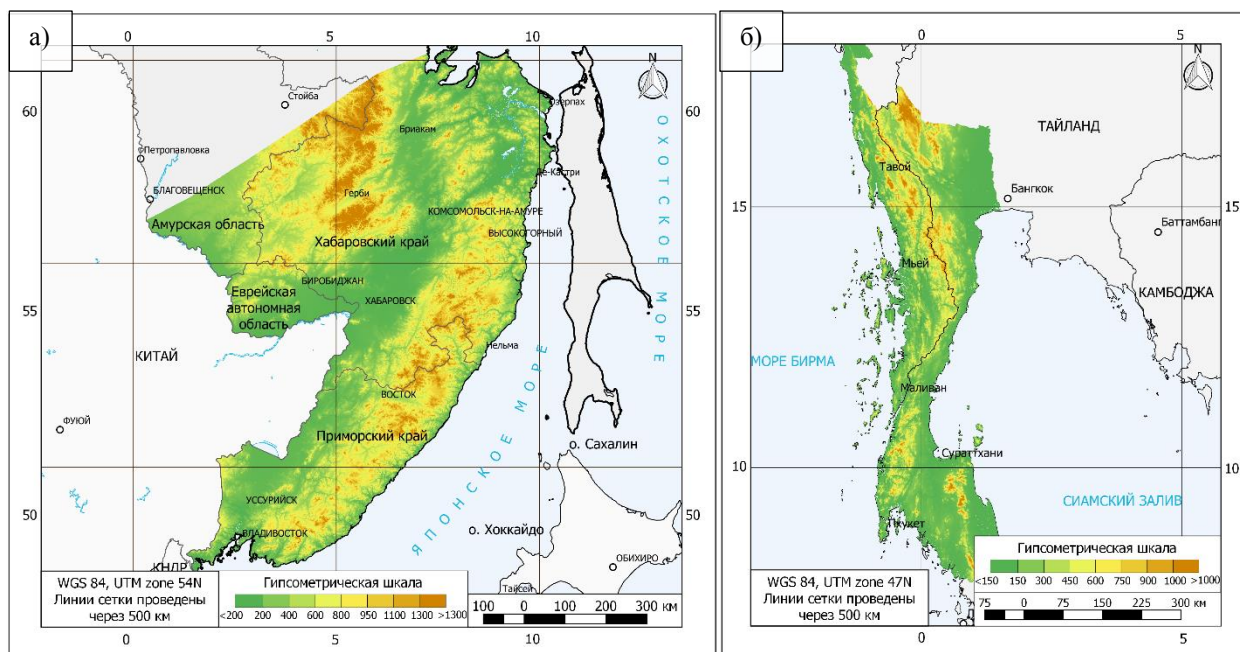


Рис.11. Цифровые модели местности на рабочие участки: а) территория Дальнего Востока: масштаб 1:12 000 000, эллипсоид – WGS 84, проекция – UTM зона 54; б) территория участка Юго-Восточной Азии: масштаб 1:6 250 000, эллипсоид – WGS 84, проекция – UTM зона 47. Линии сетки проведены через 500 км.

2.6.3 Топографическая коррекция

Рельеф местности также способен оказывать воздействие на качество получаемого результата, что затрудняет дальнейший анализ, особенно при работе с временными сериями (Holben, Justice, 1980). Для устранения его влияния была проведена топографическая коррекция.

Рельеф подстилающей поверхности может оказывать влияние несколькими способами. Во-первых, как правило, оптическая плотность изменяется с высотой. Во-вторых, в горных районах при определенных условиях большая часть объектов местности может оказаться в тени, что занижит их значения на снимке. В-третьих, поверхности с хорошими отражательными свойствами, расположенные под уклоном (например, снег на склоне), могут влиять на яркость объектов на соседнем склоне, завышая их величины. И, наконец, взаимное расположение источника излучения, объекта местности и принимающего сенсора, а также уклон поверхности порождают «эффект направления и уклона» (Meyer, Itten et al., 1993).

Однако влиянием первого фактора можно было пренебречь. Была использована приближенная формула Рэлея для определения оптической плотности атмосферы (Bodhaine, Wood et al., 1999):

$$\tau_R(\lambda, z) = 0.0088 * \lambda^{-4.15+0.2\lambda} * e^{-0.1188z-0.00116z^2} \quad (21)$$

где $\tau_R(\lambda, z)$ – оптическая плотность по Рэлею, λ – длина волны (мкм), z – высота местности над уровнем моря (км). В таблице 5 представлены значения плотности для волн видимого диапазона и высотных ступеней: 0, 100, 500, 1000 и 2000 м, а также относительная ошибка, получаемая при замене этих высот плоской поверхностью на уровне моря. Как показали результаты и рельеф рабочих участков, средняя и максимальная ошибки определения оптической плотности составляли около 6% и 22% соответственно; причем наибольшие отклонения наблюдались в отдельных точках.

Таблица 5

Оптическая плотность по Рэлею для волн видимого диапазона и относительная ошибка их определения

$\lambda(\text{нм})$ $z(\text{м})$	450 (красный)		555 (зеленый)		630 («синий»)	
	$\tau_R(\lambda, z)$	$\delta, \%$	$\tau_R(\lambda, z)$	$\delta, \%$	$\tau_R(\lambda, z)$	$\delta, \%$
0	0.255	0	0.095	0	0.056	0
100	0.222	1.3	0.094	1.1	0.055	1.8
500	0.212	5.8	0.089	6.3	0.053	5.4
1000	0.200	11.1	0.084	11.6	0.050	10.7
2000	0.177	21.3	0.074	22.1	0.044	21.4




Рис.12. Анализ времени съемки и высоты Солнца: а) распределение используемых снимков Landsat-7 и Landsat-8 в течение года и высота Солнца над горизонтом на период съемки; б) время съемки

Орбита Landsat проходит на высоте около 705 км и является солнечно-синхронной (<https://www.usgs.gov/land-resources/nli/landsat>). Съемка каждой из территории происходила приблизительно в одинаковое время в районе полудня, когда Солнце расположено в зените¹,

¹ На самом деле в положении, близкое к зениту (Рис.12б). Например, в Таиланде Солнце 2 раза в год бывает точно в зените, однако на графике кривая не достигает оси x. Поскольку время съемки для этой территории происходило приблизительно за полтора часа до полудня, то высота Солнца окажется меньше на $15^\circ \cdot 1.5 \text{ ч} \approx 22^\circ$, где 15° – угол, на который Земля поворачивается за 1 час.

а его высота в летний период составляет 60° и 70°, а в зимний – 20° и 50° для первой и второй области соответственно (Рис.12). Поэтому влиянием теней, образованных формами рельефа, можно было пренебречь.

Как показала практика, завышение значений на близлежащих склонах, вызванное высокой отражательной способностью поверхности, пренебрежимо мало. В итоге влияние рельефа сводится к воздействию последнего фактора – эффекта направления и уклона. Эмпирически-статистический метод не учитывает направления склонов, косинусный подход работает только с ламбертовыми поверхностями и не использует информацию о положении сенсора относительно объектов местности в отличие от улучшенного алгоритма Миннаэрта (Richter, Kellenberger et al., 2009). Для коррекции был использован алгоритм С-коррекции (C-correction), который показал наилучший результат среди прочих¹:

$$\rho_H = \rho_T \frac{\cos \theta_s + c_k}{\cos \beta + c_k} \quad (22)$$

где ρ_H – значение, исправленное за рельеф, ρ_T – текущее значение, θ_s – зенитный угол Солнца, β – угол солнечного освещения, c_k – константа для канала k, которая может быть найдена по формуле:

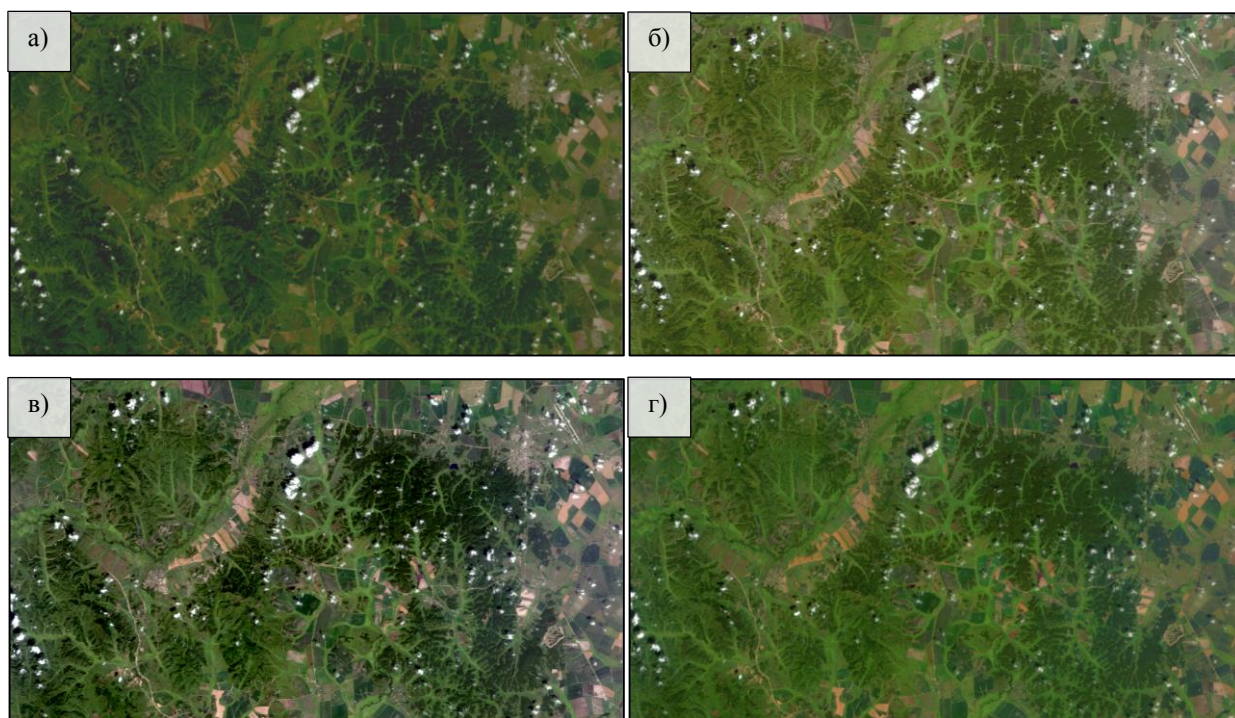


Рис. 13. Предварительная обработка снимка Landsat-8 Path-114 Row-29 на 20.08.2014: а) исходное изображение; б) после радиометрической калибровки; в) после проведения атмосферной коррекции; г) после проведения топографической коррекции

¹ Во всех подобных случаях качество рассчитывалось, исходя из сравнения результатов классификации до и после коррекции.

$$c_k = \frac{b_k}{a_k} \quad (23)$$

Значения a_k и b_k находятся из решения МНК системы уравнений вида¹:

$$\rho_T = a_k + b_k * \cos \beta \quad (24)$$

На Рис.13г представлено изображение, полученное после проведения топографической коррекции.

2.6.4 Выявление облаков, теней от облаков и снежного покрова

Облачный покров резко завышает, а тени от облаков – занижают значения на снимках, делая эти территории непригодными для дальнейшего анализа (Asner et al., 2001; Martinuzzi, Gould et al., 2007). Поскольку обе рабочие области расположены вблизи океана и подвержены его воздействию, эта задача особенно актуальна (Рис.14).




Рис.14. Куммуляты облачности для обеих территорий: а) территория Дальнего Востока, снимки собраны на период с 01.01.2010 по 01.03.2019; б) территория Юго-Восточной Азии, снимки собраны на период с 01.01.2015 по 01.03.2019

Каждый из снимков Landsat имеет канал BQA (Таблица 2), который представляет из себя битовый вектор (Рис.15а), кодирующий маски для облаков, теней, снега и др. (<https://www.usgs.gov/land-resources/nli/landsat/landsat-collection-1-level-1-quality-assessment-band>) и основанный на FMask алгоритме – по ряду наиболее информативных индексов и порогов, подобранных для них, вычисляется класс каждого пикселя (Zhu, Woodcock, 2012). Однако такой подход имеет существенный недостаток: анализируется только один снимок. Внешний вид облаков может сильно варьироваться в разных частях мира и зависит от физических и оптических свойств атмосферы; тени затемняют участки с разной интенсивностью; снежный покров также неодинаков, что зависит от его толщины, наличия других примесей и т.д.

В этой работе использовался подход TMask, предложенный Ч.Чжу и К.Вудкоком, по автоматическому нахождению облаков, теней и снега на основе анализа временной серии с

¹ В целях экономии места здесь приведен только общий вид уравнений.

использованием зеленого, ближнего и коротковолнового ИК каналов (Zhu, Woodcock, 2014b).

TMask включает в себя 3 этапа:

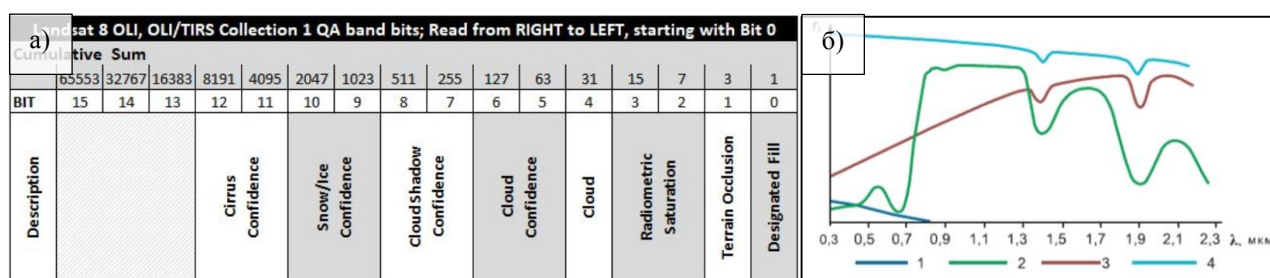


Рис.15. Кодировка канала BQA и спектральные кривые: а) кодировка канала BQA. Источник: URL:

<https://www.usgs.gov/land-resources/nli/landsat/landsat-collection-1-level-1-quality-assessment-band>; б) кривые

спектральных яркостей: 1 – снежный и облачный покров, 2 – растительность, 3 – почвы, 4 – водная поверхность. Источник: Книжников Ю.Ф. Аэрокосмические методы исследования. – с. 33

1) Инициализация. Подсчитывается количество «чистых» (свободных от снега, облаков и теней) пикселей в серии. Если их оказывается меньше 15, то применяется BackUp подход, поскольку в этом случае алгоритм не сможет правильно классифицировать объекты.

2) BackUp. Для каждой «неснежной» области вычисляется медиана по всей серии в зеленом канале. После чего проверяется неравенство:

$$B3 \leq median + 0.04 \quad (25)$$

Если оно выполняется, то пиксель считается «чистым»; в противном случае, ему присваивается метка «облачности». Для пикселей, которые оказались покрыты снегом в некоторый момент времени (для которых не использовался медианный фильтр) решение об отнесении к нужному классу принимает FMask.

3) TMask. Это основной этап алгоритма. Входными данными для него являются все «чистые» пиксели, полученные на первой и второй стадиях. Для каждого канала применяется разложение на составляющие (для каждого снимка серии):

$$\rho = a_0 + a_1 * \cos\left(\frac{2\pi}{T} * t\right) + b_1 * \sin\left(\frac{2\pi}{T} * t\right) + a_2 * \cos\left(\frac{2\pi}{NT} * t\right) + b_2 * \sin\left(\frac{2\pi}{NT} * t\right) \quad (26)$$

где a_0 – коэффициент для обнаружения общих изменений; a_1 и b_1 – коэффициенты, отвечающие за годовые изменения и a_2 и b_2 – коэффициенты для внутригодовых перемен, T – количество дней в году, t – номер дня съемки по Юлианскому календарю, N – продолжительность серии в годах. Заданную систему уравнений можно решить по МНК. Вычисленные коэффициенты используются для получения тренда и остатка. Сравнивая остатки с порогами, подобранными эмпирическим путем, можно выделить облака, снежный покров и тени от облаков. Пиксели, не попавшие ни в один из классов, считаются «чистыми».

Все приведенные выше пороги подбирались в процессе оптимизации. В целом TMask справился с задачей лучше, чем FMask (Рис.16 и Рис.17). Однако он не всегда справляется с

нахождением теней (Рис.17). Решением данной проблемы может быть объектно-ориентированный подход, который отыскивает облачность и путем сдвига в зависимости от ее высоты и направления освещения определяет области потенциальных теней, отсеивая тем самым районы, где их заведомо не может быть (Goodwin, Collet et al., 2013; Blaschke, 2010).




Рис.16. Сравнение алгоритмов FMask и TMask: а) территория Таиланда, снимок Landsat-8 Path-129 Row-54 на 22.11.2016; б) FMask ложно опознал тени вдоль побережья; в) Tmask более аккуратно выделил районы с облачностью и тенями; г) территория Хабаровского края, несколько севернее устья р.Амур, снимок Landsat-8 Path-111 Row-23 на 21.10.2015; д) Fmask ложно выделил многочисленные участки в тени гор как тень от облаков; е) TMask в целом выделил лучше, но допустил ошибки в определении снега и облаков. Красный – облака, синий – тени от облаков, желтый – снег. Комбинация каналов: SWIR2, NIR, green.

2.6.5 Фильтрация

Как уже упоминалось выше, для дальнейшей работы были необходимы 6 каналов: red, blue, green, NIR, SWIR1, SWIR2, а также 3 индекса, рассчитанные на их основе: NDVI, NDWI, NDSI. Поэтому исходная временная серия разбивалась на 9 рядов: по одному на каждый компонент. В дальнейшем каждая подобная серия рассматривается как самостоятельная, поэтому все последующие действия должны быть повторены для каждой из них.

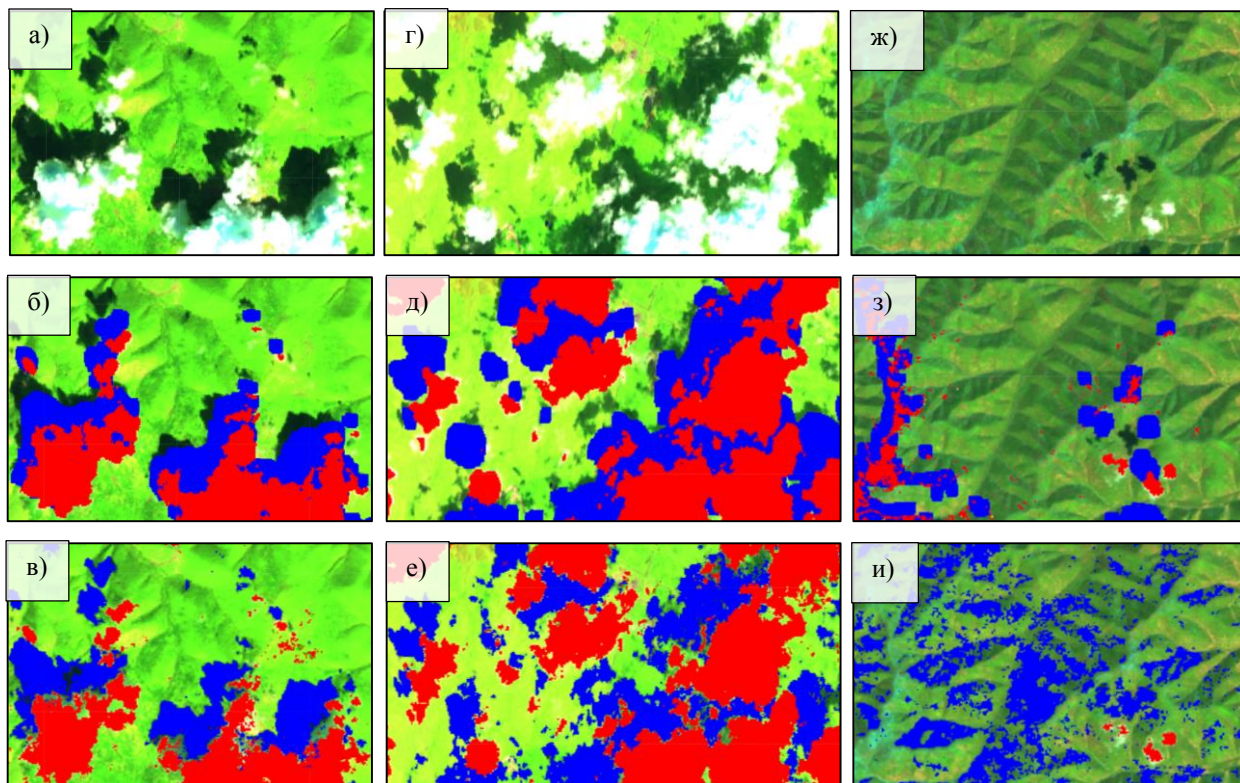


Рис.17. Сравнение алгоритмов FMask и TMask (продолжение): а, г) территория Хабаровского края, снимок Landsat-8 Pat-112 Row-25 на 09.10.2014; б, д) Fmask не выделил полностью или ложно определил области теней; в, е) TMask правильно выделил все облака и тени; ж) территория Приморского края вблизи ООПТ «Сихотэ-Алинь», снимок Landsat-8 Path-111 Row-28 на 25.04.2014; з) Fmask определил снег на горном хребте как облачность; и) провал TMask – выделение затемненных склонов как теней

Данные, прошедшие все описанные выше этапы обработки, могут содержать случайные отклонения, которые не были учтены или обнаружены упомянутыми методами. В процессе съемки размер теней, отбрасываемых объектами на земной поверхности, постоянно меняется из-за изменений угла съемки и высоты Солнца; в атмосфере могут образовываться сверхтонкие облака, которые алгоритм не всегда способен выделить; области теней от облаков иногда могут «сливаться» с затемненными участками снимка (например, с затапливаемыми территориями), что также затрудняет их поиск; атмосферная коррекция не рассматривает в полную меру все особенности района, позволяя лишь учесть основные характеристики атмосферы и т.д.

Для решения этого вопроса вся временная серия последовательно разбивалась на группы, к которым применялся медианный фильтр. Каждая группа изображений включала в себя снимки, попавшие в N-дневный интервал. Поскольку временное разрешение Landsat-7 и Landsat-8 составляет 16 дней, было принято $N = 16$. Это гарантировало, что в каждую группу попадало не менее 3-х изображений, а территория не претерпевала сильных изменений за это время. В дальнейшем, планируется использовать данные со спутников Sentinel-2 с временным разрешением 5 дней, что позволит увеличить количество снимков в группе до 6.

В Главе 1 упоминалось, что пространственное разрешение каналов Sentinel-2 и Landsat отличаются. Поэтому необходимо сначала воспользоваться одной из техник слияния для приведения данных к единому виду. Подход ATPRK обладает лучшими качествами, позволяя учитывать PSF (Рис.1) и влияние произвольного количества соседей.

Рис.15б показывает полосы поглощения для некоторых типов объектов в зависимости от длины волны. Облака в зеленом (0.555 мкм), красном (0.680 мкм) и в ближнем ИК (0.8-0.9 мкм) диапазонах имеют похожие, но завышенные значения. Поэтому NDVI будет относительно низким. На Рис.20в-г показан результат применения медианного фильтра к результатам TMask алгоритма для NDVI и зеленого канала. Заметно, что неотфильтрованные данные содержат много выбросов, которые не были отбракованы на предыдущих этапах. Рис.21а-б иллюстрирует влияние фильтрации на построение гармонической модели.



Рис.18. Набор данных для одной рубки (плантации) после разбиения временной серии на 9 групп и формирования срезов длительностью 6-7 лет. Для рубок начальная дата совпадает с датой ее обнаружения, а для плантаций – равна 01.03.2019; конечная – берется за 6-7 лет до начальной.

2.7 Формирование временных срезов и построение гармонической модели

На этом этапе необходимо было создать временной срез для каждой рубки (плантации): конечная дата – дата обнаружения (для рубки) или 01.03.2019¹ (для плантации), начальная – выбирается за 6-7 лет до конечной (Рис.18). Такой большой интервал был необходим для построения гармонической модели. Поскольку известна дата обнаружения рубки в конкретном месте (такие данные можно хранить, например, в отдельном слое векторного формата), то формирование среза было всегда возможно.

¹ Данных по датам обнаружения плантаций нет.

Нахождение рубок осуществлялось путем сравнения исходных данных с теоретическими. Поэтому сначала моделировалось поведение объектов во времени. Для этого были сделаны следующие предположения:

- лесные системы устойчивы: резкие изменения могут быть связаны только с деятельностью человека (рубки) или со стихийными бедствиями (пожары);
- лесные системы подвержены сезонным колебаниям, в которых они проходят через одни и те же фазы приблизительно в одно и то же время;
- в каждой точке снимка возможно построить периодическую функцию, описывающую ожидаемые значения в этом месте в любое время; поведение функции зависит только от фенологических особенностей данной территории;
- рубки леса резко нарушают ход фенологической кривой, что позволяет обнаружить время их возникновения;
- сравнение исходного значения с предсказанным позволит отнести рассматриваемую территорию к рубкам с определенной вероятностью.

Подобные предположения были сделаны и в отношении плантации каучука. В начале этой главы говорилось о том, что их появление может быть связано с активной вырубкой тропических лесов или с повторным сельскохозяйственным освоением ранее использованных земель. Помимо этого, каучук имеет ярко выраженные жизненные фазы, которые могут быть видны на снимках.

Для моделирования временных срезов была использована гармоническая функция, имеющая вид уравнения (16). Ее выбор обусловлен тем, что она является периодической, быстро реализуемой и легко интерпретируемой (см. «Гармонические модели»). Первое свойство очевидно связано с тем, что модель полностью состоит из периодических функций. При этом наложение последующих синусоид выделяет характерные особенности в пределах больших периодов (Рис.19), где в пределах горба «зеленой» кривой выделяется подъем и спад второй, уточняющей функции («синяя» кривая), и т.д.

В реальности функция (16) может иметь следующие порядки и их интерпретации¹:

- нулевой порядок (второе слагаемое равно 0): представляет из себя среднее значение, рассчитанное для всего временного периода;
- первый порядок ($i=1$): описывает общие сезонные циклические изменения, происходящие в природе. На Рис.20а показан NDVI, где он имеет выраженные максимумы в летний период и характерные минимумы в зимний. На Рис.20б представлен ход кривой отражательной способности в зеленом диапазоне, которая принимает наибольшие значения зимой, когда

¹ Имеется в виду интерпретация каждого последующего слагаемого в уравнении (16).

выпадает снежный покров. Второй, но меньший по размеру максимум возникает летом, что связано с обильным лиственным покровом;




Рис.19. Примеры гармонических функций (ГФ) разных порядков. Черный – среднее значение a_0 за весь период; зеленый – ГФ 1-ого порядка (содержит 3 коэффициента: a_0, a_1, b_1); синий – ГФ 2-ого порядка (включает 5 коэффициентов: a_0, a_1, b_1, a_2, b_2); красный – ГФ 3-его порядка (7 коэффициентов: $a_0, a_1, b_1, a_2, b_2, a_3, b_3$)

- второй порядок ($i=2$): характеризует изменения в течение сезонов, которые могут быть вызваны, например, погодными условиями местности в данное время года. На Рис.21б в 2016 году наблюдается большая депрессия по сравнению с другими годами, что может быть связано с более холодной осенью;
- Третий порядок ($i=3$): в основном подчеркивает особенности течения того или иного периода, например, позволяя сделать выводы о том, в какие дни теплого сезона наиболее интенсивно появляется лиственный покров. Однако этот случай не имеет ярко выраженного воздействия в отличие от выше описанных вариантов.

В этой работе использовалась гармоническая функция третьего порядка. Более высокие порядки трудно интерпретировать, а их влияние на результат будет несущественным.

Описанную модель просто реализовать, потому что нахождение неизвестных коэффициентов по МНК легко свести к уравнению вида (1), которое будет иметь решение. Построение гармонической функции было выполнено для каждой временной серии каждого пикселя отдельно. Если, например, одна рубка имеет размер на снимке 10 пикселей, то для нее будет составлено $10 \times 9 = 90$ уравнений вида (16), для каждого из которых подбираются 7 коэффициентов независимо от других. Рис.21а-б визуализирует отрывки двух таких кривых для одной из точек.

2.8 Создание и обучение нейронной сети

После предыдущего шага каждый пиксель содержал всю необходимую информацию для последующего обучения¹:

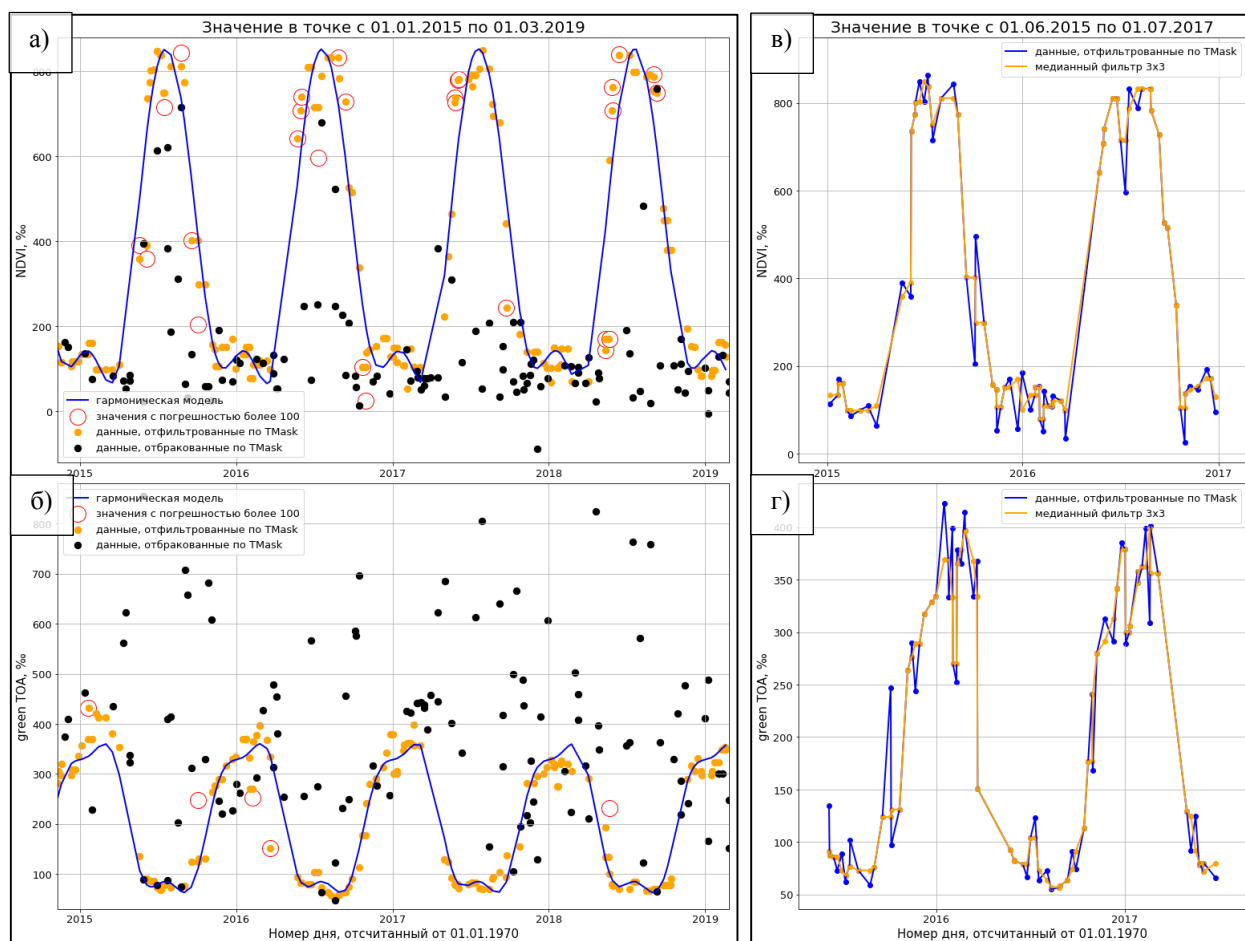


Рис.20. Построение гармонических кривых для точки с координатами 49°15' с.ш. 137°42' в.д.: а, б) подобранная ГФ² 3-его порядка для NDVI (а) и зеленого канала (б); в, г) результат медианной фильтрации для NDVI (в) и зеленого канала (г). Черные точки – исходные данные, синие точки – данные, выделенные по TMask, оранжевые точки – отфильтрованные данные, красные точки – точки до фильтрации, значения которых отличаются от построенных кривых более, чем на 0.1, синяя линия – ГФ (а, б) и исходная кривая (в, г), оранжевая линия – кривая после фильтрации. Размер окна медианного фильтра – 16 дней

- | | | |
|----------------------------|-----------------------------------|---------------------------|
| – значение в канале red; | – значение NDWI; | – гармоники для swir2; |
| – значение в канале green; | – значение NDSI; | – гармоники для NDVI; |
| – значение в канале blue; | – гармоники ³ для red; | – гармоники для NDWI; |
| – значение в канале nir; | – гармоники для green; | – гармоники для NDSI; |
| – значение в канале swir1; | – гармоники для blue; | – дата обнаружения рубки. |
| – значение в канале swir2; | – гармоники для nir; | |
| – значение NDVI; | – гармоники для swir1; | |

¹ Представленная ниже схема использовалась для обнаружения рубок. Для плантации была она была видоизменена (Глава 3).

² ГФ – гармоническая функция.

³ Имеются в виду коэффициенты гармонических функций.

Характеристики (признаки) для каждого пикселя представлены в Таблице 6, которая понадобилась для обучения. При этом данные из таблицы можно условно разделить на две группы. К первой относятся представленные выше девять фактических значений и дата. Они описывают текущее состояние каждого пикселя. Во вторую группу входят оставшиеся коэффициенты, вычисленные для каждого канала и индекса. Эта совокупность характеризует ожидаемое состояние тех же пикселей, рассчитанное по гармоническим функциям. Причем само ожидаемое значение не вычислялось; оно полностью определялось семью коэффициентами, которые были подобраны для каждой кривой¹.

В работе использовались векторные слои, в которых были представлены около 1000 известных рубок и порядка 800 плантаций каучука с общим количеством пикселей приблизительно 75 000 и 40 000 соответственно. При этом каждый пиксель характеризуется набором свойств подобно точке с известными координатами. В таком случае каждая строка таблицы – это вектор, где в роли координат выступают свойства пикселя, количество которых равно 73. Для анализа большого количества многомерных данных был использован подход машинного обучения с учителем: многослойный персептрон (multilayer perceptron, MLP).

Таблица 6

Таблица признаков

	Значение в канале red	...	Гармоника для red: a_0	Гармоника для red: b_1	...	Дата
пиксель 1	red_1	...	a_{01}	b_{01}	...	d_1
пиксель 2	red_2	...	a_{02}	b_{02}	...	d_2
...
пиксель m	red_m	...	a_{0m}	b_{0m}	...	d_m

Результаты нейронных сетей очень трудно интерпретировать из-за огромного количества связей в них. Однако они подходят для решения сложных задач, в которых данные описываются широким набором параметров. На сегодняшний день в обработке ДДЗ используют различные архитектуры сетей: персептроны, рекуррентные, сверточные и др. (Zhu, Tuia et al., 2017) Наиболее простыми являются первые, поэтому именно они и использовались. Сверточные сети способны распознавать образы объектов, что может оказаться полезным для обнаружения рубок и плантаций, которые, как правило, имеют правильную геометрическую форму. Но для их реализации требуется много вычислительных ресурсов.

¹ Практика показала, что результат не изменится, если вместо коэффициентов взять вычисленное по ним предсказанное значение.

В сфере машинного обучения нет единого стандарта и подхода к выбору того или иного метода оценивания. Как правило, критерий выбирается, исходя из ситуации. На практике используют широкий набор показателей, характеризующих качество обученной модели с различных точек зрения (Флах, 2015). Для проведения оценки применялись верность (accuracy), точность (precision) и полнота (recall):

$$accuracy = P(\hat{c}(x) = c(x)) = \frac{TA}{N} \quad (27)$$

$$precision = P(c(x) = 1 | \hat{c}(x) = 1) = \frac{TP}{TP + FP} \quad (28)$$

$$recall = P(\hat{c}(x) = 1 | c(x) = 1) = \frac{TP}{Pos} \quad (29)$$

где N – размер выборки, $c(x)$ – истинные значения, $\hat{c}(x)$ – значения, предсказанные моделью, TA – все правильные ответы, TP – правильные положительные ответы, FP – ложноположительных¹ ответов, Pos – общее количество положительных примеров.

Критерий (27) служит для оценки общего качества модели, позволяя охарактеризовать ее способность различать классы между собой. Точность (28) показывает соотношение положительных ответов среди всех выделенных алгоритмом рубок (плантаций). Наконец, полнота (29) определяет долю всех найденных рубок (плантаций).

Для построения нейронной сети использовался следующий итеративный подход (Рис.10):

1. инициализация сети трехслойным персептроном с тремя нейронами в каждом слое;
2. обучение сети на имеющихся данных;
3. оценка качества модели с использованием уравнений (27) - (29);
4. изменение параметров сети;
5. повторение п.2-п.4, пока не будут перебраны все заданные возможные варианты параметров для нейронной сети;
6. выбор такой конфигурации сети, при которой ошибки, посчитанные в п.3, минимальны.

Устанавливать при инициализации сети менее 3 слоев или нейронов нет смысла, поскольку такая сеть будет иметь очень низкую способность к обучению. Для сравнения качества модели предпочтение отдавалось, в первую очередь, верности и полноте, потому что важно найти и выделить как можно больше рубок (плантаций); при этом оценка ложных выделений играет второстепенную роль.

MLP модель имеет два основных параметра: количество скрытых слоев и число нейронов в каждом из них. Библиотека Scikit-learn языка Python предоставляет инструмент

¹ То есть отнесенные алгоритмом к категории рубок (плантаций), но на самом деле, такими не являющиеся.

GridSearch, позволяющий перебрать все возможные комбинации параметров в заданном интервале каждого из них, и выбрать тот набор, который дает наименьшую ошибку. Так как число нейронов может меняться от слоя к слою, то фактически количество параметров оказывается равным: $N-1$, где N – число слоев. Вычитание единицы связано с тем, что во входном слое количество нейронов должно совпадать с числом характеристик данных. Такой процесс требует много ресурсов, поэтому было решено оставить 3 слоя, изменяя при этом только количество нейронов во втором и третьем слоях.

Важно отметить несколько особенностей. Во-первых, для обучения сети и подбора параметров использовалось только 70% исходного материала. На остальных 30% обученная модель тестировалась, то есть проверялась ее способность корректно работать с новыми данными, которые не были использованы ранее. Во-вторых, все значения, которые могут принимать признаки, не должны быть большими по абсолютной величине, потому что метод градиентного спуска (см. 2.2.4) основан на расчете производной. Чем больше значение переменной, тем более пологой становится активирующая функция (Рис.5), тем ближе значение производной к нулю и, в конечном счете, ниже скорость обучения. Поскольку в расчетах использовались каналы, значения которых были приведены к отражательной способности, то это гарантирует, что возможный диапазон значений для каждого из них составлял $[0..1]$. Значения трех индексов по определению заключено в интервал $[-1..1]$. Исходя из уравнения гармонической кривой (16), можно заключить, что коэффициенты не были намного больше независимой переменной. Однако дата, которая равна номеру дня по Юлианскому календарю, оказалась большой по величине. Поэтому, этот признак был приведен к диапазону $[0..255]$ ¹.

2.9 Предсказание меток классов

Построенная и обученная нейронная сеть использовалась для предсказания меток каждого пикселя: «change» (произошли изменения) или «no-change» (изменений не было). При этом сама модель определяла не номер класса, а вероятность отнесения к тому или иному классу по методу максимальной апостериорной оценки (см. 2.2.3). В результате, каждому пикселю присваивалась метка класса, имевшего наибольшую вероятность.

Однако такой подход ничего не говорит о том, насколько давно были замечены произошедшие изменения. Для этого метки всех пикселей сохранялись в отдельном файле. После этого проводился сравнительный анализ. Если, например, какой-либо пиксель получил

¹ Для того, чтобы каждая дата соответствовала только одному значению из диапазона, было принято, что 01.01.2000 является 0 и 01.01.2050 отображается на 255.

метку «change», то информация о нем искалась в файле. Если оказывалось, что он ранее получал такую же метку, то это означает, что рубка уже была обнаружена, и этот пиксель в итоге относился к классу «old change» (старые изменения). В противном случае он считался бы представителем класса «new change» (новые изменения). Таким образом, окончательный ответ алгоритма заключался в отнесении каждого пикселя снимка к одной из категории: «old changes», «new changes» или «no-changes».

Таким образом, в качестве исходных данных использовались снимки Landsat-7 и Landsat-8, а также векторный слой с информацией по рубкам и плантациям. Из них формировалась таблица признаков, которая использовалась в обучении нейронной сети. Полученные результаты содержали метку класса, которая сравнивалась с предыдущими маркерами для достижения окончательного результата.

Глава 3. Использование алгоритма для выделения рубок и плантаций каучука

В этой главе коротко описаны основные особенности, которые были учтены при работе с двумя разными территориями.

3.1 Особенности использования алгоритма для выделения вырубок

Несмотря на схожесть обеих территорий, между ними есть отличия, которые были приняты во внимание. Регион Дальнего Востока расположен в умеренных широтах, для которых характерно наличие летнего и зимнего сезонов. В соответствии с этим, при проведении атмосферной коррекции была выбрана соответствующая модель атмосферы.

Этот же фактор приводит к тому, что лесной массив на снимках будет выглядеть по-разному в зависимости от сезона. В результате, совместный анализ всех изображений становится затруднительным. Поэтому вся коллекция рубок была условно разбита на 2 группы: летняя (с апреля по сентябрь) и зимняя (с октября по март) серии. Для каждой из них была создана и обучена отдельная нейронная сеть в соответствии с методикой, приведенной в разделе 2.8. Рис.21 отражает зависимость точности¹ модели от количества нейронов во втором и третьем слоях для обучающего и тестового множества для двух примеров: на летний и зимний сезоны. В точках В и С, обе оценки имеют максимально близкое значение. Во втором примере это значение также является и наибольшей точностью для тестового набора, в отличие от первого, где максимальная точность достигается в точке А. В общем случае, обе величины могут не совпадать («летний» вариант). Поэтому использование первой из них не всегда дает максимально возможную оценку точности, но гарантирует, что модель не окажется недообученной² или переобученной³.

Таким образом, наилучшей нейронной сетью для летнего сезона являлась модель, определяемая в т.В, где количество нейронов для второго и третьего слоев равно 50 и 30 соответственно. Аналогично, для работы со снимками, полученными в зимний сезон, использовалась сеть с параметрами, значения которых задаются координатами т.С: 20 и 50. Использование большего числа нейронов потребовало бы больше вычислительных ресурсов и, как видно из Рис.21, не дало бы существенного прироста к точности тестового множества.

¹ Представленная характеристика является верностью (ассигасу - «точность»), определяемой уравнением (27).

² Недообученная модель характеризуется высокой обобщающей способностью и, как правило, низкой оценкой точности.

³ Для переобученной модели характерно наличие низкой обобщающей способности, высокой зависимости от шумов и, как правило, оценка для тестовой выборки оказывается ниже, чем для обучающей.

Для обучающей выборки это привело бы к росту оценки – сеть окажется переобученной. В таблице 7 приведены значения разных оценок для «летней» и «зимней» сетей.

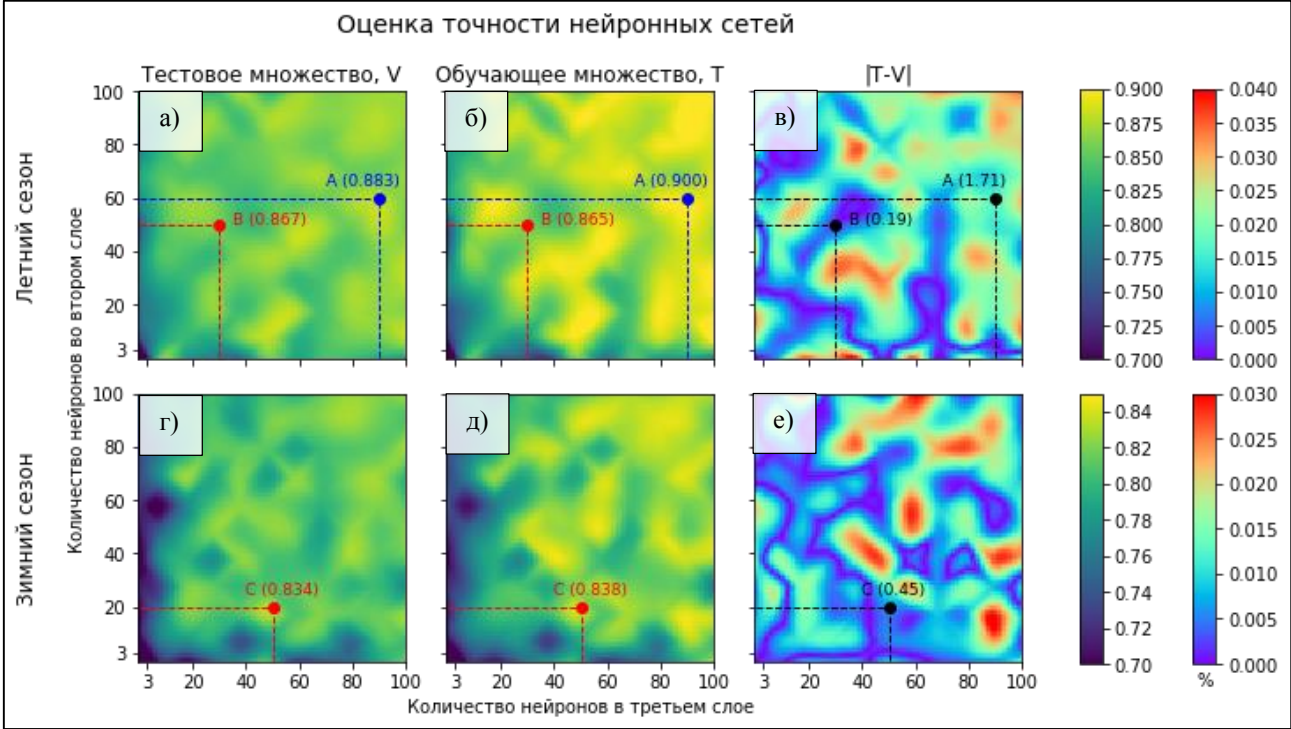


Рис.21. Оценка точности нейронных сетей для территории Дальнего Востока: а-в) летний сезон; г-е) зимний сезон; а, г) тестовое множество, V; б, д) обучающее множество, T; в, е) абсолютная разность оценок для V и T. т.А – достигается максимальное значение на V, модель переобучена, так как $t \gg v^1$; т.В – значения на V и T оказываются наиболее близкими ($t \approx v$), причем $v > t$; т.С – здесь одновременно значения v и t имеют минимальную разницу и v достигает максимума, хотя $t < v$, такой вариант допустим

Таблица 7

Значения оценок нейронных сетей для тестового множества

	Верность	Точность	Полнота
Дальний Восток (лето)	0.867	0.769	0.934
Дальний Восток (зима)	0.834	0.784	0.912
Юго-Восточная Азия	0.888	0.751	0.907

Расположение двух территорий в разных частях мира и в различных климатических поясах приводит к несколько различающимся значениям облачного и снежного покровов и теней на снимках. Поэтому все параметры алгоритма TMask подбирались отдельно для каждой из них.

На Рис.22а-в показана серия летних снимков на небольшой участок южной части Хабаровского края, на которых отчетливо видно увеличение площади, занятых вырубками, в

¹ t – оценка на обучающем множестве, v – оценка на тестовом множестве; знак >> означает «много больше» не в строгом смысле этого слова.

период с 2012 года по 2018 год. В 2012 (а) на представленном участке фрагментарно располагалось несколько небольших по размеру рубок и одна крупная. Через 3 года (б) их количество резко возросло: появились новые в северной и западной частях снимка¹. На 2018 год (в) активная незаконная деятельность затронула западный и южный районы изображения. На последнем рисунке (г) представлен результат работы алгоритма, на котором каждый пиксель имеет значение, показывающее вероятность отнесения его к классу «change». Практически все рубки оказались или выделены полностью, или идентифицированы (то есть на их территории есть участки, опознанные алгоритмом).

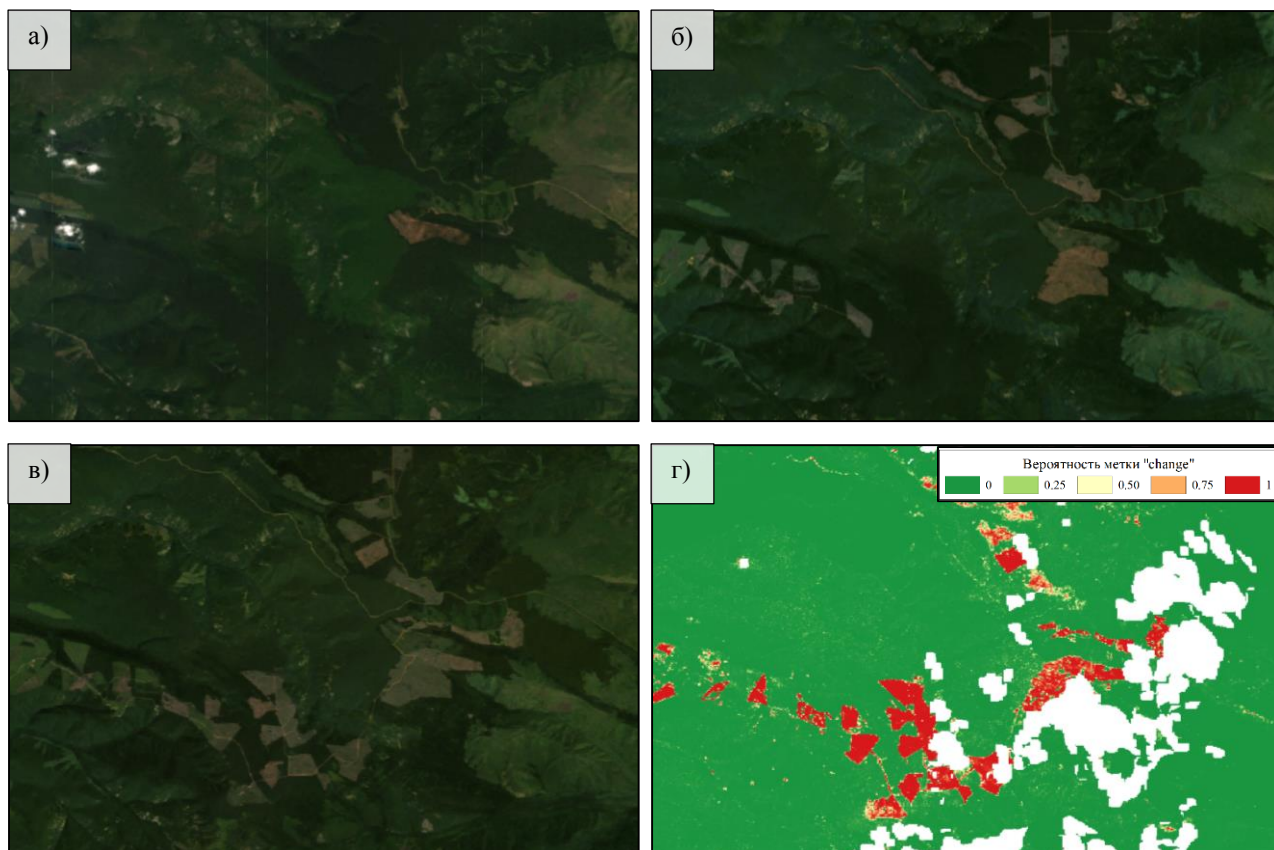


Рис.22. Результаты работы алгоритма для снимка на летний сезон: а) снимок Landsat-7 Path-110 Row-26 на 23.06.2012 (пропуски заполнены снимком Landsat-7 Path-110 Row-26 на 07.06.2012); б) снимок Landsat-8 Path-111 Row-25 на 02.08.2015; в) снимок Landsat-8 Path-111 Row-25 на 10.08.2018, для которого применялся алгоритм; г) результаты алгоритма. Все изображения даны в естественных цветах. Темно-зеленый – $p^2 \approx 0$ (точнее $p \leq 10^{-6}$), зеленый – $p \in (0; 0.25]$, желтый – $p \in (0.25; 0.5]$, оранжевый – $p \in (0.5; 0.75]$, красный – $p \in (0.75; 1]$, белый – нет данных. Территория – юг Хабаровского края

На Рис.23 показан пример работы алгоритма на зимний период для участка в южной части Амурской области. В 2013 (а) существовало несколько крупных вырубок на юге и востоке этой территории. К 2018 году (б) вся центральная часть участка оказалась подвержена

¹ Имеется в виду частях представленного фрагмента снимка, поскольку все изображение значительно больше.

² p – вероятность метки «change».

деятельности браконьеров. Несмотря на то, что рубки плохо выражены на снимке (в), алгоритм правильно смог выделить все участки, затронутые человеком (г). Помимо этого, удалось опознать новые дороги и подъезды к рубкам, возникшие с 2012.




Рис.23. Результаты работы алгоритма для снимка на зимний сезон: а) снимок Landsat-7 Path-116 Row-26 на 06.07.2013 (пропуски заполнены снимком Landsat-7 Path-116 Row-26 на 22.07.2013); б) снимок Landsat-8 Path-116 Row-26 на 28.07.2018; в) снимок Landsat-8 Path-116 Row-26 на 19.12.2018, для которого применялся алгоритм; г) результаты алгоритма. Все изображения даны в естественных цветах. Темно-зеленый – $p \approx 0$ (точнее $p \leq 10^{-6}$), зеленый – $p \in (0; 0.25]$, желтый – $p \in (0.25; 0.5]$, оранжевый – $p \in (0.5; 0.75]$, красный – $p \in (0.75; 1]$, белый – нет данных. Территория – юг Амурской области

3.2 Особенности использования алгоритма для выделения плантаций каучуковых деревьев

В Юго-Восточной Азии нет летних и зимних периодов в том понимании, в каком они представлены на территории дальневосточного региона РФ: климат характеризуется низкими амплитудами годовой температуры и бесснежными зимами. Кроме того, этот район расположен в других климатических поясах, что обуславливает следующие особенности при работе с ним.

Во-первых, выше уже указывалось, что алгоритм TMask настраивался обособленно от первой территории. Во-вторых, для проведения атмосферной коррекции была использована тропическая модель атмосферы, задаваемая в 6S методе. В-третьих, для обучения была

создана только одна нейронная сеть¹. При этом в качестве признаков пикселей использовался набор данных, отличный от представленного в 2.8, так как для плантаций неизвестны даты их обнаружения. Поэтому алгоритму требовалось относить каждый пиксель к некоторому классу безотносительно к конкретной дате. Для этого также использовались гармонические функции, строившиеся на определенный период. Но на этот раз совокупность коэффициентов каждой такой кривой полностью определял тип объекта. Исходя из этого, набор признаков для обучения выглядел так:

- гармоники для red; – гармоники для green; – гармоники для blue;
- гармоники для nir; – гармоники для swirl1; – гармоники для swirl2;
- гармоники для NDVI; – гармоники для NDSI; – гармоники для NDWI;

Сам процесс обучения не претерпевал никаких изменений.

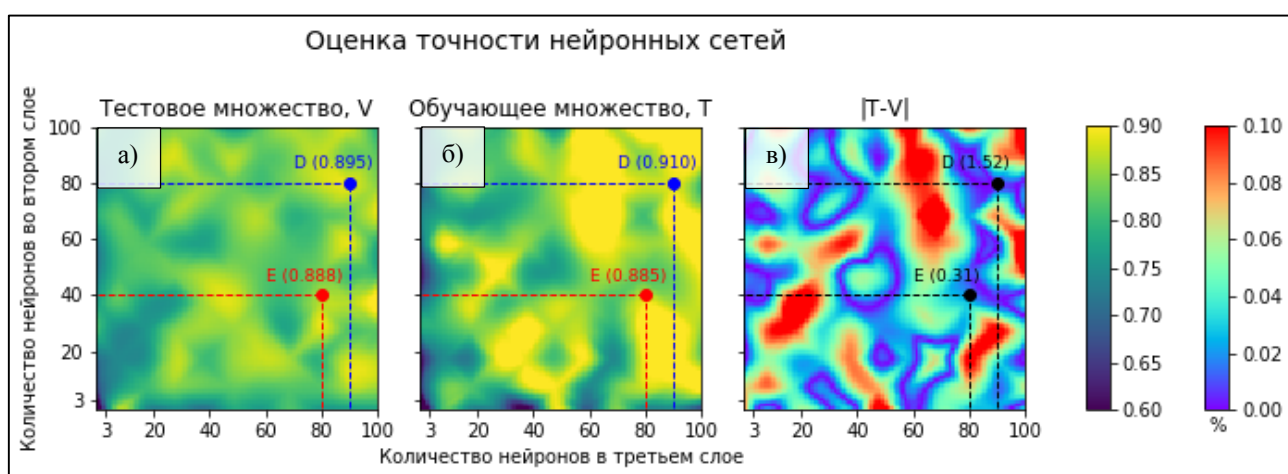


Рис.24. Оценка точности нейронных сетей для территории Юго-Восточной Азии: а) тестовое множество, V; б) обучающее множество, T; в) абсолютная разность оценок для V и T. т.D – достигается максимальное значение на V, модель переобучена, так как $t \gg v$; т.E – значения на V и T оказываются наиболее близкими ($t \approx v$), причем $v > t$

На Рис.24 представлен результат анализа нейронной сети для рабочей области. Также, как и в случае Рис.23а-в, точка, в которой модель имеет наивысшую оценку для тестового множества (т.D), не совпадает с выбором, где обе точности – для тестового и обучающего наборов, наиболее похожи (т.E). В Таблице 7 приведены значения оценок для этого региона. На Рис.25 представлено 3 фрагмента одного и того же участка на зимний период 2013 (а), 2016 (б) и 2018 (в) годов и результат работы алгоритма (г). Для удобства сравнения на последних двух рисунках изображены полигоны, которые участвовали в обучении сети.

При рассмотрении Рис.22-23 и Рис.25 заметно, что в большинстве своем рубки хорошо выделяются на снимке, а потому результаты алгоритма можно достаточно просто

¹ Как показала практика, особенности различных сезонов в Юго-Восточной Азии не влияют на результат.

визуально сравнить с их изображениями. Задача обнаружения плантаций несколько сложнее, потому что их сложно отличить от другого типа растительности (см. 1.4). Об этом свидетельствуют и результаты Таблицы 7, где точность обнаружения плантаций в целом была хуже, чем для рубок. Высокое значение верности для плантаций вызвано большим количеством пикселей в обучающей¹ выборке, не являющимися ими. В случаях, подобных этому, когда объекты неравномерно распределены по классам, верность не является надежной характеристикой. Относительно низкая точность говорит о том, что алгоритм ложно определяет другие объекты местности (дороги, реки и т.д.) как плантации. Высокое значение полноты означает, что около 90% всех плантаций оказалось выделено.

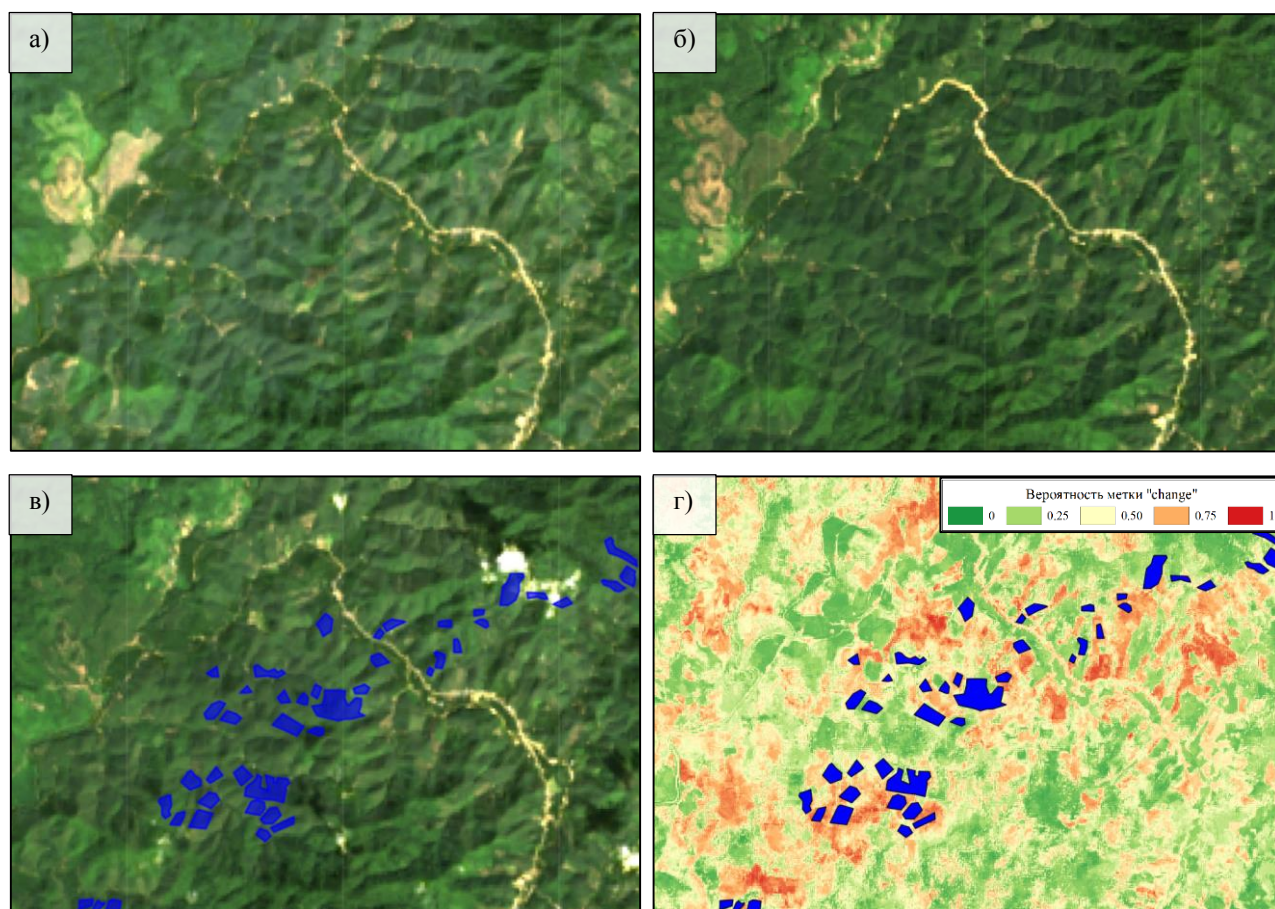


Рис.25. Результаты работы алгоритма: а) снимок Landsat-8 Path-130 Row-52 на 23.12.2013; б) снимок Landsat-8 Path-130 Row-52 на 31.12.2016; в) снимок Landsat-8 Path-130 Row-52 на 21.12.2018; г) результаты алгоритма. Все изображения даны в естественных цветах. Темно-зеленый – $p \approx 0$ (точнее $p \leq 10^{-6}$), зеленый – $p \in (0; 0.25]$, желтый – $p \in (0.25; 0.5]$, оранжевый – $p \in (0.5; 0.75]$, красный – $p \in (0.75; 1]$, белый – нет данных; синие полигоны – обучающая выборка. Территория – северная часть провинции Ранонг (Таиланд)

¹ Здесь под обучающим множеством имеется в виду весь набор исходных данных, который участвовал в настройках нейронных сетей. Первая его часть – собственно обучающая выборка, использовалась для обучения, а вторая, тестовый набор – для оценки.




Рис.26. Выделение плантаций каучука: а) исходный снимок Landsat-8 Path-130 Row-52 на 21.12.2018; б) «карта» вероятностей, где темно-зеленый – $p \approx 0$ (точнее $p \leq 10^{-6}$), зеленый – $p \in (0; 0.25]$, желтый – $p \in (0.25; 0.5]$, оранжевый – $p \in (0.5; 0.75]$, красный – $p \in (0.75; 1]$; в) присвоение меток по методу максимальной апостериорной оценки; г) отфильтрованное изображение (в) для исключения шумов

На Рис. 26 показаны последовательные шаги алгоритма для выделения плантаций каучука, а на Рис.27 – карта с полученными результатами.

Подводя итоги, важно заметить, что несмотря на то, что для выделения и рубок, и плантаций каучука использовался один и тот же алгоритм, необходимо учитывать особенности рассматриваемой территории. Кроме того, выделение плантаций является более сложной задачей, потому что в этом случае задача алгоритма – найти не резкие изменения (как в случае с рубками), а различать виды гармонических кривых для разных типов объектов.

Результат выделения плантаций каучука.
Северная часть провинции Ранонг (Таиланд)

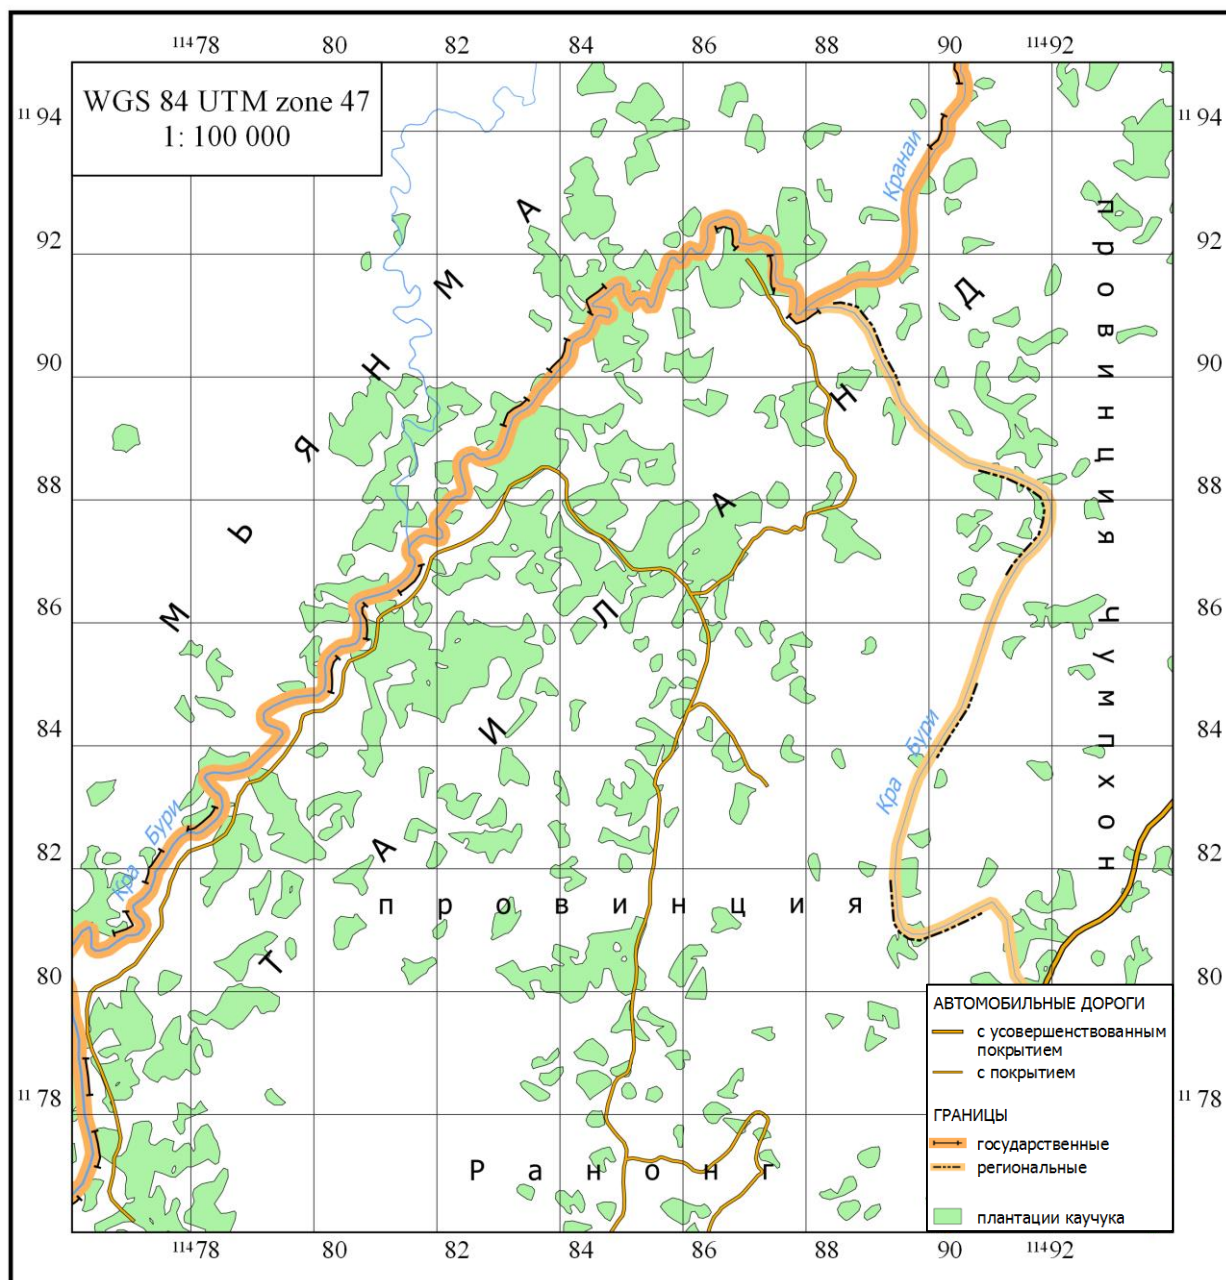


Рис.27. Картографирование плантаций каучука на основе данных, полученных из Рис.26. Масштаб 1: 100 000; эллипсоид – WGS 84; проекция UTM зона 47. Зеленые полигоны – области, являющимися плантациями по решению алгоритма.

Заключение

Результатом этой работы является разработанный алгоритм, который может применяться в системах мониторинга лесных рубок или плантаций каучука. При этом были выполнены следующие задачи:

- рассмотрены основные методики, применяемые сегодня в системах мониторинга с использованием ДДЗ, и выявлены их недостатки, которые учитывались при проектировании представленного в работе алгоритма;
- проведена предварительная обработка космических снимков Landsat-7 и Landsat-8, включающая в себя радиометрическую калибровку, атмосферную и топографическую коррекции, поиск облачности, теней и медианную фильтрацию;
- сформированы временные срезы и построены по ним гармонические функции для нахождения ожидаемых значений на интересующую дату;
- построены и обучены нейронные сети для каждой территории; при этом на дальневосточный регион было создано две: для зимнего и летнего периодов;
- произведена оценка качества нейронных сетей, которые были применены к новым данным для поиска рубок (плантаций);

На каждом из этапов алгоритма были рассмотрены существующие подходы для решения конкретной задачи и всегда выбирались методы, дающие наилучший результат в условиях работы с рассматриваемыми территориями. Точность полученных результатов сравнима с качеством других алгоритмов, применяемых в системах мониторинга, превосходя некоторые из них. При этом, предложенный здесь алгоритм обладает рядом преимуществ:

- является более универсальным;
- включает многоступенчатую предварительную обработку для лучшего исключения шумов;
- использует возможности нескольких спутниковых систем для достижения большего временного разрешения;
- требует минимум усилий от человека: настроенный и оптимизированный вручную он в дальнейшем будет собирать новые данные и включать их в обработку.

В дальнейшем, планируется использовать данные Sentinel-2 вместе с Landsat-7 и Landsat-8. Для этого будет встроен отдельный этап по приведению к единому пространственному разрешению снимков этих спутников. Это позволит увеличить ежемесячное количество получаемых снимков с 4-5 до 11-12, что важно для территорий с большим количеством облачных дней в году.

Кроме того, будет рассмотрен вариант замены алгоритма для выделения облачности TMask объектно-ориентированным аналогом, что резко снизит количество ложных выделений теней.

Список литературы:

1. Незаконные рубки на Дальнем Востоке: мировой спрос на древесину и уничтожение Уссурийской тайги: обзор / А. Г. Кабанец, Б. Д. Милаковский, Е. А. Лепешкин, Д. В. Сычиков; под общ. ред. Д. Ю. Смирнова; Всемирный фонд дикой природы (WWF). – М.: WWF России, 2013. – 39 с.
2. Флах П. Машинное обучение: Наука и искусство построения алгоритмов, которые извлекают знания из данных / пер. с англ. А. А. Слинкина. – М.: ДМК Пресс, 2015. – 400 с. [Flach P. Machine Learning: The Art and Science of Algorithms that Make Sense of Data : Cambridge University Press, 2012].
3. Asner G.P. et al. Cloud cover in Landsat observations of the Brazilian Amazon // International Journal of Remote Sensing. – 2001. Vol. 22. No. 18. – P. 3855-3862. – ISSN 0143-1161.
4. Blaschke T. Object based image analysis for remote sensing // ISPRS Journal of Photogrammetry and Remote Sensing. – 2010. Vol. 65. – P. 2-16. – ISSN 0924-2716.
5. Bodhaine B.A., Wood N.B., Dutton N.G., Slusser J.R. On Rayleigh Optical Depth Calculations // Journal of Atmospheric and Oceanic Technology. – 1999. Vol. 16 – P. 1854-1861. – ISSN 1520-0426.
6. Chander G., Markham B.L., Helder D.L. Summary of Current Radiometric Calibration Coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI Sensors // Remote Sensing of Environment. – 2009. Vol. 113. No. 5. – P. 893-903. – ISSN 0034-4257.
7. Chen J., Zhu X., Vogelmann J.E. et al. A simple and effective method for filling gaps in Landsat ETM+ SLC-off images // Remote Sensing of Environment. – 2011. Vol. 115. No. 4. – P. 1053-1064. – ISSN 0034-4257.
8. Du Q., Younan N.H., King R. et al. On the Performance Evaluation of Pan-Sharpening Techniques // IEEE Geoscience and Remote Sensing Letters. – 2007. Vol. 4. No. 4. – P. 518-522. – ISSN 1545-598X.
9. Gao F., Masek J., Schwaller M. et al. On the Blending of the Landsat and MODIS Surface Reflectance: Predicting Daily Landsat Surface Reflectance // IEEE Transactions on Geoscience and Remote Sensing. – 2006. Vol. 44. No. 8. – P. 2207-2218. – ISSN 0196-2892.
10. Goodfellow I., Bengio Y., Courville A. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – London: The MIT Press, 2016. – 802 p.
11. Goodwin N.R., Collet L.J., Denham R.J. et al. Cloud and cloud shadow screening across Queensland, Australia: An automated method for Landsat TM/ETM+ time series // Remote Sensing of Environment. – 2013. Vol. 134. – P. 50-65. – ISSN 0034-4257.

12. Grogan K., Pflugmacher D., Hostert P. et al. Cross-border forest disturbance and the role of natural rubber in mainland Southeast Asia using annual Landsat time series // *Remote Sensing of Environment*. – 2015. Vol. 169. – P. 438-453. – ISSN 0034-4257.
13. Howard A., Rorres C. *Elementary Linear Algebra* / A. Howard, C. Rorres. – 9th edition – Hoboken, New Jersey: Wiley, 2004. – 624 p.
14. Fox J., Castella J.C., Ziegler A.D. Swidden, Rubber and Carbon: Can REDD+ work for people and the environment in Montane Mainland Southeast Asia? // *Global Environmental Change*. – 2014. Vol. 29. – P. 318-326. – ISSN 0959-3780.
15. Fox J., Vogler J.B. Land-Use and Land-Cover Change in Montane Mainland Southeast Asia // *Journal of Environmental Management*. – 2005. Vol. 36. No. 3. – P. 394-403. – ISSN 0301-4797.
16. Fraser R.S., Kaufman Y.J. The Relative Importance of Aerosol Scattering and Absorption in Remote Sensing // *IEEE Transactions on Geoscience and Remote Sensing*. – 1985. Vol. GE-23. No. 5. – P. 625-633. – ISSN 0196-2892.
17. Holben B.N., Justice C.O. The Topographic Effect on Spectral Response from Nadir-Pointing Sensors // *Photogrammetric Engineering and Remote Sensing*. – 1980. Vol. 46. No. 9. – P. 1191-1200. – ISSN 0099-1112
18. Kaufman Y.J., Tanré D., Gordon H.R. et al. Passive remote sensing of tropospheric aerosol and atmospheric correction for the aerosol effect // *Journal of Geophysical Research*. – 1997. Vol. 102. No. D14. – P. 16,815-16,830. – ISSN 0148-0227.
19. Kowalik W.S., Marsh S.E. A Relation Between Landsat Digital Numbers, Surface Reflectance, and the Cosine of the Solar Zenith Angle // *Remote Sensing of Environment*. – 1982. Vol. 12. No. 1. – P. 39-55. – ISSN 0034-4257.
20. Liang S., Fang H., Chen M. Atmospheric Correction of Landsat ETM+ Land Surface Imagery—Part I: Methods // *IEEE Transactions on Geoscience and Remote Sensing*. – 2001. Vol. 39. No. 11. – P. 2490-2498. – ISSN 0196-2892.
21. Li Z., Fox J.M. Integrating Mahalanobis typicalities with a neural network for rubber distribution mapping // *Remote Sensing Letters*. – 2010. Vol. 2. No. 2. – P. 157-166. – ISSN 2150-704X.
22. Li Z., Fox J.M. Mapping rubber tree growth in mainland Southeast Asia using time-series MODIS 250 m NDVI and statistical data // *Applied Geography*. – 2012. Vol. 32. No. 2. – P. 420-432. – ISSN 0143-6228.
23. Lucht W., Schaaf C.B., Strahler A.H. An Algorithm for the Retrieval of Albedo from Space Using Semiempirical BRDF Models // *IEEE Transactions on Geoscience and Remote Sensing*. – 2017. Vol. 38. No. 2. – P. 977-998. – ISSN 0196-2892.

24. Martinuzzi S., Gould W.A., Ramos González O.M. Creating Cloud-Free Landsat ETM+ Data Sets in Tropical Landscapes: Cloud and Cloud-Shadow Removal // General Technical Report (GTR). – 2007. – 18 p.
25. Maxwell S.K., Schmidt G.L., Storey J.C. A multi-scale segmentation approach to filling gaps in Landsat ETM+ SLC-off images // International Journal of Remote Sensing. – 2007. Vol. 28. No. 23. – P. 5339-5356. – ISSN 0143-1161.
26. Meyer P., Itten K.I., Kellenberger T. et al. Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment // ISPRS Journal of Photogrammetry and Remote Sensing. – 1993. Vol. 48. No. 4. – P. 17-28. – ISSN 0924-2716.
27. Musthafa M., Singh G., Khati U. DETECTION OF FOREST DISTURBANCE USING TANDEM-X POL-INSAR COHERENCE // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS Archives). – 2018. Vol. XLII-5. – P. 295-297. – ISSN 1682-1777.
28. Pithon S., Jubelin G., Guitet S. et al. A statistical method for detecting logging-related canopy gaps using high-resolution optical remote sensing // International Journal of Remote Sensing. – 2012. Vol. 34. No. 2. – P. 700-711. – ISSN 0143-1161.
29. Pushparaj J., Hegde A.V. Comparison of various pan-sharpening methods using Quickbird-2 and Landsat-8 imagery // Arabian Journal of Geosciences. – 2017. Vol. 10. No. 5. – P. 1-17. – ISSN 1866-7511.
30. Rashid T. Make Your Own Neural Network / T. Rashid. – Scotts Valley: CreateSpace, 2016. – 222 p.
31. Richter R., Kellenberger T., Kaufmann H. Comparison of Topographic Correction Methods // Remote Sensing. – 2009. Vol. 1. – P. 184-196. – ISSN 2072-4292.
32. Roy D.P., Ju J., Lewis P. et al. Multi-temporal MODIS–Landsat data fusion for relative radiometric normalization, gap filling, and prediction of Landsat data // Remote Sensing of Environment. – 2008. Vol. 112. No. 6. – P. 3112-3130. – ISSN 0034-4257.
33. Sahoo P. Probability and mathematical statistics / P. Sahoo. – Louisville, Kentucky: University of Louisville, 2013. – 712 p.
34. Shrestha R.P., Schmidt-Vogt D., Gnanavelrajah N. Relating plant diversity to biomass and soil erosion in a cultivated landscape of the eastern seaboard region of Thailand // Applied Geography. – 2010. Vol. 30. No. 4. – P. 606-617. – ISSN 0143-6228.
35. Tang D., Fan H., Yang K. et al. Mapping forest disturbance across the China–Laos border using annual Landsat time series // International Journal of Remote Sensing. – 2019. Vol. 40. No. 8. – P. 2895–2915. – ISSN 0143-1161.

36. Tang X., Bullock E.L., Olofsson P. et al. Near real-time monitoring of tropical forest disturbance: New algorithms and assessment framework // *Remote Sensing of Environment*. – 2019. Vol. 224. – P. 202-218. – ISSN 0034-4257.
37. Thiel C., Drezet P., Weise C. et al. Radar remote sensing for the delineation of forest cover maps and the detection of deforestation // *Forestry: An International Journal of Forest Research*. – 2006. Vol. 79. No. 5. – P. 589-597. – ISSN 0015-752X.
38. Thome K., Markharn B., Barker J. et al. Radiometric Calibration of Landsat // *Photogrammetric Engineering and Remote Sensing*. – 1997. Vol. 63. No. 7. – P. 853-858. – ISSN 0099-1112.
39. Vanonckelen S., Lhermitte S., Rompaey A. The effect of atmospheric and topographic correction methods on land cover classification accuracy // *International Journal of Applied Earth Observation and Geoinformation*. – 2013. Vol. 24. – P. 9-21. – ISSN 0303-2434.
40. Vermote E.F., Tanré D., Deuzé J.L. et al. Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: An Overview // *IEEE Transactions on Geoscience and Remote Sensing*. – 1997. Vol. 35. No. 3. – P. 675-686. – ISSN 0196-2892.
41. Wang Q., Atkinson P.M. The effect of the point spread function on sub-pixel mapping // *Remote Sensing of Environment*. – 2017. Vol. 193. – P. 127-137. – ISSN 0034-4257.
42. Wang Q., Blackburn G.A., Onojeghuo A.O. et al. Fusion of Landsat 8 OLI and Sentinel-2 MSI Data // *IEEE Transactions on Geoscience and Remote Sensing*. – 2017. Vol. 55. No. 7. – P. 3885-3899. – ISSN 0196-2892.
43. Zhang C., Li W., Travis D. Gaps-fill of SLC-off Landsat ETM+ satellite image using a geostatistical approach // *International Journal of Remote Sensing*. – 2007. Vol. 28. No. 22. – P. 5103-5122. – ISSN 0143-1161.
44. Zhang Y. Understanding Image Fusion // *Photogrammetric Engineering and Remote Sensing*. – 2004. Vol. 70. No. 6. – P. 657-661. – ISSN 0099-1112.
45. Zhu X.X., Tuia D., Mou L. et al. Deep Learning in Remote Sensing: A comprehensive review and list of resources // *IEEE Geoscience and Remote Sensing Magazine*. – 2017. Vol. 5. No. 4. – P. 8-36. – ISSN 2473-2397.
- 46a. Zhu Z., Woodcock C.E. Automated cloud, cloud shadow, and snow detection in multitemporal Landsat data: An algorithm designed specifically for monitoring land cover change // *Remote Sensing of Environment*. – 2014. Vol. 152. – P. 217-234. – ISSN 0034-4257.
- 46b. Zhu Z., Woodcock C.E. Continuous change detection and classification of land cover using all available Landsat data // *Remote Sensing of Environment*. – 2014. Vol. 144. – P. 152-171. – ISSN 0034-4257.
47. Zhu Z., Woodcock C.E. Object-based cloud and cloud shadow detection in Landsat imagery // *Remote Sensing of Environment*. – 2012. Vol. 118. – P. 83-94. – ISSN 0034-4257.

Ресурсы сети Интернет:

48. Вдовенко А.В., Кононов Ю.В. ПРИМЕНЕНИЕ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ДЛЯ МОНИТОРИНГА ЗЕМЕЛЬ ЛЕСНОГО ФОНДА // электронное науч. изд. «Ученые заметки ТОГУ». – 2013. Т. 4. № 4. – С. 1860-1865. – ISSN 2079-8490. URL: http://pnu.edu.ru/media/ejournal/articles-2014/TGU_4_336.pdf (дата обращения: 01.02.2019).
49. Казаков Э., Семёнов А., Волгушева Н. Обработка и интерпретация данных Landsat 8 (OLI) средствами GRASS GIS 7. – 2015. URL: <http://gis-lab.info/qa/grass7-landsat8-processing.html> (дата обращения: 02.02.2019).
50. Система мониторинга «КЕДР». URL: <https://wwf.ru/resources/news/lesa/na-dalnem-vostoke-rossii-vnedryaetsya-unikalnaya-sistema-kedr> (дата обращения: 09.11.2018).
51. Шимов С.В., Никитина Ю.В. Технология мониторинга вырубок леса с использованием космических снимков высокого пространственного разрешения // интернет-журн. «Геоматика». – 2011. № 3. – С. 47-52. – ISSN 2410-6879. URL: https://sovzond.ru/upload/iblock/b75/7shimov_tekhnologia_monitoringa_virybok_lesa.pdf (дата обращения: 06.02.2019).
52. Google Earth Engine: A planetary-scale platform for Earth science data & analysis. URL: <https://earthengine.google.com> (дата обращения: 01.09.2018).
53. Ma F., Wang, Q., Zhang M. Dynamic changes of wetland resources based on MODIS and Landsat image data fusion // EURASIP Journal on Image and Video Processing. – 2018. Vol. 63. – 10 p. – ISSN 1687-5281. URL: <https://jivp-urasipjournals.springeropen.com/articles/10.1186/s13640-018-0305-7> (дата обращения: 10.10.2018).
54. Fonseca L., Namikawa L., Castejon E. et al. Image Fusion for Remote Sensing Applications // Image Fusion and Its Applications / Y. Zheng, IntechOpen. – 2011. – P. 153-178. URL: <https://www.intechopen.com/books/image-fusion-and-its-applications/image-fusion-for-remote-sensing-applications> (дата обращения: 25.01.2019).
55. TensorFlow: An end-to-end open source machine learning platform. URL: <https://www.tensorflow.org> (дата обращения: 25.01.2019).
56. USGS. Landsat Missions. URL: <https://www.usgs.gov/land-resources/nli/landsat> (дата обращения: 09.12.2018).
57. USGS. Landsat Missions: Landsat Collection 1 Level-1 Quality Assessment Band. URL: <https://www.usgs.gov/land-resources/nli/landsat/landsat-collection-1-level-1-quality-assessment-band> (дата обращения: 22.11.2018).
58. USGS. Phase 2 Gap-Fill Algorithm: SLC-off Gap-Filled Products Gap-Fill Algorithm Methodology // электронная статья. – 2004. – 12 p. URL: <https://landsat.usgs.gov/sites/default/files/documents/L7SLCGapFilledMethod.pdf> (дата обращения: 12.11.2018).